

UNIVERSIDADE FEDERAL DO PARANÁ

MARINA VARGAS REIS DE PAULA GONÇALVES

SIMULAÇÃO DA MOVIMENTAÇÃO DE PEDESTRES ASSUMINDO
VARIÁVEIS PSICOCOMPORTAMENTAIS

CURITIBA

2014

MARINA VARGAS REIS DE PAULA GONÇALVES

SIMULAÇÃO DA MOVIMENTAÇÃO DE PEDESTRES ASSUMINDO
VARIÁVEIS PSICOCOMPORTAMENTAIS

Tese apresentada ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Área de Concentração em Programação Matemática, do Departamento de Matemática e Departamento de Engenharia de Produção, Setor de Ciências Exatas e do Departamento de Construção Civil, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Doutor em Ciências.

Orientadora: Profa. Dra. Liliana Madalena Gramani

Coorientador: Prof. Dr. Marco André Argenta

Coorientador: Prof. Dr. Eloy Kaviski

CURITIBA

2014

G635s

Gonçalves, Marina Vargas Reis de Paula

Simulação da movimentação de pedestres assumindo variáveis psicocomportamentais / Marina Vargas reis de Paula Gonçalves. – Curitiba, 2014.

137f. : il. color. ; 30 cm.

Tese (doutorado) - Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-graduação em Métodos Numéricos em Engenharia, 2014.

Orientadora: Lilitiana Madalena Gramani -- Co-orientador: Marco André Argenta -- Co-orientador: Eloy Kaviski.

Bibliografia: p. 131-137.

1. Tráfego de Pedestres. 2. Variáveis Psicocomportamentais. 3. Inteligência Artificial. 4 Modelagem Computacional I. Universidade Federal do Paraná. II. Gramani, Lilitiana Madalena. III. Argenta, Marco André. IV. Kaviski, Eloy. V. Título.

CDD: 511.8

Ao meu marido Marco e as nossa filhas gêmeas Manuela e Laura.

AGRADECIMENTOS

Aos meus pais, Júlio e Ana Luiza, por todo o apoio sempre e incondicional aos meus estudos e nas minhas decisões de vida.

A minha irmã Marcela, por podermos compartilhar experiências e com isso aprender sempre mais.

Ao meu marido e co-orientador, Prof. Dr. Marco André Argenta, pois sem seu apoio nada teria sido realizado. Foi a minha inspiração.

As minhas filhas. Por seus sorrisos e beijinhos nas horas mais difíceis.

Aos meus sogros, Jeime e Elair, por me ajudarem tantas vezes em casa, com as meninas, quando eu precisei estudar.

Aos meus amigos Tati, Vanessinha, Guilherme, Fábio, Maiko, Lu, Vânia, Josué, Sandro e, me perdoem os que esqueci, por me fornecerem tantos bons momentos de discussão, de relaxamento e muitos sorrisos durante esses quatro anos.

A Profa. Dra. Liliana M. Gramani, por me orientar desde o início da minha vida como pesquisadora.

Não poderia deixar de fora nossa eterna secretária do PPGMNE, Maristela Bandil. Minha querida amiga.

Agradeço a CAPES pelo apoio financeiro e a todos os funcionários do CESEC, da Biblioteca e até da Cantina pela ajuda, pelo espaço sempre limpo, pelos cafezinhos, em todas as ocasiões.

Várias pessoas me auxiliaram neste trabalho. A todos só posso dizer: Muito Obrigada!

Se enxerguei mais longe, foi por me erguer sobre os ombros de
gigantes.

Sir Isaac Newton

RESUMO

O objetivo deste trabalho é o desenvolvimento de um modelo físico-matemático computacional utilizando inteligência artificial para simulação e análise da movimentação de pedestres, em ambientes que podem gerar comportamentos desordenados devido a altos níveis de estresse. Aliando Inteligência Artificial, que inclui raciocínio probabilístico, aprendizagem de máquina e conceitos de robótica é possível simular o deslocamento de pedestres assumindo variáveis psicocomportamentais para que esses agentes possam distinguir situações virtuais impostas pelo ambiente e tomar decisões. Estudos de fluxo de pedestres foram empreendidos, em especial nas últimas três décadas. Entretanto, a existência de fatores psicocomportamentais transforma esse tipo de sistema em algo extremamente complexo. Se o organismo de um pedestre é submetido a situações desconfortáveis ou de impotência ocorre um aumento na ansiedade que gera estresse. Esse estresse produz uma cadeia de reações que podem variar de irritabilidade, desorientação e até pânico. Essa gama de variáveis pode alterar o fluxo pedonal de forma significativa e é justamente esse o maior problema quando se procura um modelo de movimentação de pedestres. A modelagem computacional é viabilizada utilizando-se linguagem de programação Python, por ser uma linguagem de alto nível, otimizada para o programador ou seja, de fácil implementação e aprendizado, possui vários ambientes integrados e é portátil a todos os sistemas operacionais, além de ter módulos para processamento gráfico. O entendimento da movimentação de pedestres, tendo como foco principal seu comportamento, permite expandir a análise para ambientes mais complexos resultando em uma ferramenta de auxílio em situações com multidões em diferentes ambientes. Neste trabalho desenvolveu-se um modelo bidimensional com visualização tridimensional de um ambiente genérico, simulando-se agentes inteligentes desconfortáveis, representativas de comportamentos psicológicos humanos genéricos, capazes de identificar situações e tomar decisões. Comparações com trabalhos já constantes na literatura sobre fluxo de pedestres ilustram as discussões.

Palavras-chave: Tráfego de Pedestres. Variáveis Psicocomportamentais. Inteligência Artificial. Modelagem Computacional. Agentes BDI.

ABSTRACT

The aim of this work is to develop a physical-mathematical computational model using artificial intelligence to simulate and analyze the movement of pedestrians in environments that can generate disordered behaviors due to high stress levels. Combining Artificial Intelligence, which includes probabilistic reasoning, machine learning and robotics concepts it is possible to simulate the movement of pedestrians coupled with psycho-behavioral variables so that these agents can distinguish virtual situations imposed by the environment and make decisions. Pedestrian flow studies have been undertaken, especially in the last three decades. However, the existence of psycho-behavioral factors turns such system into something extremely complex. If the organism of the pedestrian is submitted to uncomfortable or powerlessness situations, the anxiety that creates stress increases. This stress produces a chain of reactions that can vary from irritability, disorientation and even panic. This variation can change significantly the pedestrian flow and this is the biggest problem when the aim is a representative pedestrian movement model. Computer modeling is done using the Python programming language, because it is a high-level language, optimized for programmer, ie, easy implementation and learning, has several built-in environments and is portable to all operating systems, besides having modules for graphics processing. Understanding the movement of pedestrians, focusing mainly on their behavior, allows expanding the analysis to more complex environments resulting in an auxiliary tool in situations with crowds in different environments. In this work we developed a two-dimensional model with three-dimensional visualization of a generic environment, simulating uncomfortable intelligent agents, representatives of a human generic psychological behavior, able to identify situations and make decisions. Comparisons with literature papers on pedestrian flow studies illustrate the discussions.

Key-words: Pedestrian Traffic; Psycho-behavioral variables, Artificial Intelligence, Computer Simulation.

LISTA DE FIGURAS

FIGURA 1 – GRAFOS DIRIGIDOS ACÍCLICOS.	29
FIGURA 2 – CONSTRUÇÃO DA CURVA BÉZIER CÚBICA.	51
FIGURA 3 – RECURSÃO DE DE CASTELJAU.	56
FIGURA 4 – TEM-SE QUE $P_0 = B_{0,0}$, $P_1 = B_{1,0}$, $P_2 = B_{2,0}$ E $P_3 = B_{3,0}$. FONTE: WIKIMEDIA.ORG. AUTOR: PHIL TREGONING, 2007.	57
FIGURA 5 – COMPARAÇÃO ENTRE AS DIMENSÕES DE PEDESTRES E CI- LINDROS.	58
FIGURA 6 – REPRESENTAÇÃO DO CONE DE VISÃO GIRANDO PELO AMBI- ENTE.	59
FIGURA 7 – CONE DE REVOLUÇÃO	59
FIGURA 8 – PONTO P EM XOY	60
FIGURA 9 – PLANO CARTESIANO COM PONTOS A , B E C	61
FIGURA 10– CENTROIDES	62
FIGURA 11– COLISÃO ENTRE CILINDROS.	62
FIGURA 12– COLISÃO ENTRE PARALELEPÍPEDOS E CILINDROS.	62
FIGURA 13– CAMINHADA DE UM ROBÔ DE ACORDO COM A SOLUÇÃO DE UM PF. FONTE: SEQUENTIAL MONTE CARLO METHODS IN PRACTICE, 2001.	67
FIGURA 14– CAMINHADA DE UM ROBÔ DE ACORDO COM A SOLUÇÃO DE UM PF. FONTE: A PARTICLE FILTER TUTORIAL FOR MOBILE RO- BOT LOCALIZATION, 2004.	67
FIGURA 15– PORTAS FICTÍCIAS.	68
FIGURA 16– ESCOLHA DOS PONTOS DE CONTROLE A PARTIR DO PF.	69
FIGURA 17– FLUXOGRAMA REPRESENTATIVO PARA UM AGENTE BDI SE- GUNDO UM <i>I-PLAN</i> . ADAPTADO DE RENS, FERREIN E POEL (2009).	70

FIGURA 18– REPRESENTAÇÃO DE UM CILINDRO PELO VPYTHON. FONTE: DOCUMENTAÇÃO DO VPYTHON.	74
FIGURA 19– REPRESENTAÇÃO DE UMA CAIXA NO VPYTHON. FONTE: DOCUMENTAÇÃO DO VPYTHON.	75
FIGURA 20– AGENTES ACOPLADOS A SEUS CONES DE VISÃO, FAZENDO A DETECÇÃO DE OBSTÁCULOS PARA SUAS CAMINHADAS.	76
FIGURA 21– REPRESENTAÇÃO DE UM CONE NO VPYTHON. FONTE: DOCUMENTAÇÃO DO VPYTHON.	76
FIGURA 22– DETECÇÃO DE CONTATO ENTRE O CONE DE VISÃO E AS PAREDES.	77
FIGURA 23– RASTRO DE ESFERAS. FONTE: DOCUMENTAÇÃO DO VPYTHON.	78
FIGURA 24– PONTOS DE CONTROLE ALINHADOS NAS PORTAS.	80
FIGURA 25– HIPÓTESE DE DOIS AGENTES DE CADA PERSONALIDADE CONTIDOS NO AMBIENTE DE TESTES.	84
FIGURA 26– VISUALIZAÇÕES DO AMBIENTE.	85
FIGURA 27– CHOQUES ENTRE AGENTES.	86
FIGURA 28– DECISÃO DO AGENTE RACIONAL (SALA 2) AO ENTRAR NA PORTA D. TEMPO: 3S.	87
FIGURA 29– DECISÃO DOS AGENTES RACIONAIS (SALA 1 E 2) E DOS AGENTES EMOTIVO, EXPERIMENTAL E CUSTÓDIA (SALA 2). TEMPO: 9S.	88
FIGURA 30– DECISÕES DOS AGENTES NO TEMPO: 13S.	89
FIGURA 31– DECISÃO DOS AGENTES NO TEMPO: 15S.	90
FIGURA 32– DECISÃO DOS AGENTES NO TEMPO: 19S.	90
FIGURA 33– TEMPO DE EVACUAÇÃO DAS QUATRO PERSONALIDADES. ...	91
FIGURA 34– PORTAS DE SAÍDA DO AMBIENTE DE TESTES MAIS UTILIZADAS POR CADA PERSONALIDADE.	92
FIGURA 35– NÚMERO DE VEZES QUE CADA PORTA DO AMBIENTE DE TESTES É UTILIZADA POR CADA PERSONALIDADE.	93

FIGURA 36– VELOCIDADES MÉDIAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	94
FIGURA 37– DISTÂNCIAS MÉDIAS PERCORRIDAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	94
FIGURA 38– AMBIENTE GERAL E POSIÇÃO INICIAL DOS AGENTES.	96
FIGURA 39– AMBIENTE COMPOSTO APENAS POR AGENTES RACIONAIS.	96
FIGURA 40– AMBIENTE COMPOSTO APENAS POR AGENTES EXPERIMENTAIS.	97
FIGURA 41– AMBIENTE COMPOSTO APENAS POR AGENTES CUSTÓDIAS.	98
FIGURA 42– AMBIENTE COMPOSTO APENAS POR AGENTES EMOTIVOS. .	99
FIGURA 43– AMBIENTE COMPOSTO POR UM NÚMERO MAIOR DE AGENTES RACIONAIS.	101
FIGURA 44– TEMPOS MÉDIOS DE EVACUAÇÃO DAS QUATRO PERSONALIDADES EM UM AMBIENTE COM MAIOR NÚMERO DE AGENTES RACIONAIS.	101
FIGURA 45– PORTAS DE SAÍDA DO AMBIENTE DE TESTES MAIS UTILIZADAS POR CADA PERSONALIDADE.	102
FIGURA 46– NÚMERO DE VEZES QUE CADA PORTA DO AMBIENTE DE TESTES É UTILIZADA POR CADA PERSONALIDADE.	103
FIGURA 47– VELOCIDADES MÉDIAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	104
FIGURA 48– DISTÂNCIAS MÉDIAS PERCORRIDAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	105
FIGURA 49– AMBIENTE COMPOSTO POR UM NÚMERO MAIOR DE AGENTES EXPERIMENTAIS.	106
FIGURA 50– TEMPOS MÉDIOS DE EVACUAÇÃO DAS QUATRO PERSONALIDADES EM UM AMBIENTE COM MAIOR NÚMERO DE AGENTES EXPERIMENTAIS.	107
FIGURA 51– PORTAS DE SAÍDA DO AMBIENTE DE TESTES MAIS UTILIZADAS POR CADA PERSONALIDADE.	108

FIGURA 52– NÚMERO DE VEZES QUE CADA PORTA DO AMBIENTE DE TESTES É UTILIZADA POR CADA PERSONALIDADE.	108
FIGURA 53– VELOCIDADES MÉDIAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	109
FIGURA 54– DISTÂNCIAS MÉDIAS PERCORRIDAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	110
FIGURA 55– AMBIENTE COMPOSTO POR UM NÚMERO MAIOR DE AGENTES CUSTÓDIAS.	111
FIGURA 56– TEMPOS MÉDIOS DE EVACUAÇÃO DAS QUATRO PERSONALIDADES EM UM AMBIENTE COM MAIOR NÚMERO DE AGENTES EXPERIMENTAIS.	112
FIGURA 57– PORTAS DE SAÍDA DO AMBIENTE DE TESTES MAIS UTILIZADAS POR CADA PERSONALIDADE.	113
FIGURA 58– NÚMERO DE VEZES QUE CADA PORTA DO AMBIENTE DE TESTES É UTILIZADA POR CADA PERSONALIDADE.	113
FIGURA 59– VELOCIDADES MÉDIAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	114
FIGURA 60– DISTÂNCIAS MÉDIAS PERCORRIDAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	115
FIGURA 61– AMBIENTE COMPOSTO POR UM NÚMERO MAIOR DE AGENTES EMOTIVOS.	116
FIGURA 62– TEMPOS MÉDIOS DE EVACUAÇÃO DAS QUATRO PERSONALIDADES EM UM AMBIENTE COM MAIOR NÚMERO DE AGENTES EXPERIMENTAIS.	117
FIGURA 63– PORTAS DE SAÍDA DO AMBIENTE DE TESTES MAIS UTILIZADAS POR CADA PERSONALIDADE.	118
FIGURA 64– NÚMERO DE VEZES QUE CADA PORTA DO AMBIENTE DE TESTES É UTILIZADA POR CADA PERSONALIDADE.	118
FIGURA 65– VELOCIDADES MÉDIAS E DESVIO PADRÃO, PARA CADA PERSONALIDADE.	119
FIGURA 66– DISTÂNCIAS MÉDIAS PERCORRIDAS E DESVIO PADRÃO, PARA	

CADA PERSONALIDADE.	120
FIGURA 67– MÉDIA DE TEMPO DE EVACUAÇÃO DE TODAS AS SEÇÕES ANTERIORES.	121
FIGURA 68– PORTAS DE SAÍDA MAIS UTILIZADAS POR CADA PERSONALIDADE LEVANDO EM CONSIDERAÇÃO TODAS AS SEÇÕES ANTERIORES.	122
FIGURA 69– QUANTIDADE DO USO DE PORTAS POR PERSONALIDADE. ..	123
FIGURA 70– VALOR MÉDIO DAS DISTÂNCIAS PERCORRIDAS POR CADA PERSONALIDADE EM TODAS AS SIMULAÇÕES REALIZADAS. ..	123
FIGURA 71 – VALOR MÉDIO DAS VELOCIDADES DE CADA PERSONALIDADE EM TODAS AS SIMULAÇÕES REALIZADAS.	124
FIGURA 72– SIMULAÇÃO COM AGENTES SEM CUSTOS.	125

LISTA DE SIGLAS

HCM	<i>Highway Capacity Manual</i>
TRB	<i>Transportation Research Board</i>
AI	Artificial Intelligence
MAS	Multi-Agent System
BN	Bayes Network
HMMs	Hidden Markov Models
MDPs	Markov Decision Processes
POMDPs	Partially Observable Markov Decision Processes
PDF	Probability Density Function
MLLS	Maximum Likelihood Laplace Smoothing
MCMC	Markov chain Monte Carlo
SIS	Sequential Importance Sampling
PFs	Particle Filters
BDI	Belief, Desire, Intention
FOV	Field of Vision
UFBA	Universidade Federal da Bahia

SUMÁRIO

1	INTRODUÇÃO	17
1.1	OBJETIVOS	18
1.1.1	Objetivo Geral	18
1.1.2	Objetivo Específico	18
1.2	JUSTIFICATIVA	19
1.3	CONTRIBUIÇÕES DA TESE	20
1.4	ORGANIZAÇÃO DO TEXTO	20
2	REVISÃO BIBLIOGRÁFICA	21
3	FUNDAMENTAÇÃO TEÓRICA	25
3.1	INTELIGÊNCIA ARTIFICIAL	25
3.1.1	Conceitos de Inteligência Artificial - AI	26
3.2	MODELOS PROBABILÍSTICOS	29
3.2.1	Métodos ocultos de Markov	32
3.2.2	Filtro de Partículas	34
3.3	PROCESSO DE MARKOV PARCIALMENTE OBSERVÁVEL	36
3.3.1	Descrição Matemática do Processo de Decisão de Markov Parcialmente Observável	37
3.4	AGENTE BASEADO EM CRENÇA, DESEJO E INTENÇÃO	39
3.4.1	Agentes BDI a partir de políticas ótimas de POMDPs	41
3.4.2	Passagem de Política para <i>I-Plans</i>	42
3.5	PLANEJAMENTO	43
3.6	VARIÁVEIS PSICOCOMPORTAMENTAIS	46
3.7	CURVAS DE BÉZIER	50

3.7.1 Propriedades das Curvas de Bézier	52
3.7.2 Propriedades das funções de Bernstein	53
3.7.3 Algoritmo de De Casteljaui para solução da curva de Bézier	55
3.8 INTERAÇÕES GEOMÉTRICAS	58
3.8.1 Detecção de um ponto dentro de um cone	59
3.8.2 Ponto de Intersecção entre retas finitas	60
3.8.3 Colisões entre formas geométricas dinâmicas	61
3.9 PYTHON	63
4 MÉTODOS	66
4.1 GERAÇÃO DE <i>I-PLANS</i>	66
4.1.1 Memória curta e memória longa	71
4.1.2 Combinando planejamento do POMDP com o Modelo de agente BDI	71
4.2 INTERAÇÕES ENTRE AGENTES E AMBIENTE	73
4.2.1 Agente	73
4.2.2 Paredes	74
4.2.3 Cone de Visão	75
4.2.4 Módulos Adicionais	77
4.3 PASSAGEM DE UMA BÉZIER PARA OUTRA	79
4.4 CUSTOS DE MOVIMENTAÇÃO	80
5 RESULTADOS	84
5.1 QUATRO PERSONALIDADES	84
5.2 AMBIENTE COM ÚNICA PERSONALIDADE	95
5.2.1 Agentes Racionais	96
5.2.2 Agentes Experimentais	97
5.2.3 Agentes Custódias	98
5.2.4 Agentes Emotivos	98

5.3 AMBIENTE DESBALANCEADO	99
5.3.1 Racionais em maior número	100
5.3.2 Experimentais em maior número	105
5.3.3 Custódia em maior número	110
5.3.4 Emotivos em maior número	115
5.4 PROBABILIDADES GERAIS	120
5.5 VALIDAÇÃO DOS RESULTADOS	124
6 DISCUSSÃO	126
7 CONCLUSÕES	129
8 SUGESTÃO PARA TRABALHOS FUTUROS	130
REFERÊNCIAS	131

1 INTRODUÇÃO

Um modelo é uma representação simplificada de um sistema, cuja finalidade, em geral, é fazer com que um sistema complexo e de manipulação arriscada seja apresentado em um formato de compreensão mais simples. Os modelos podem ser usados também para representar sistemas que, em operação, possam causar alguma espécie de dano ou prejuízo, de forma que, usando-se simulações não causem consequências danosas. Em alguns casos, como situações de movimentação de multidões com altos níveis de estresse por exemplo, os testes nem poderiam ser realizados, já que seria considerado antiético levar pessoas a situações de pânico e perigo sem necessidade, tendo como solução a utilização de simulações. Quando refere-se a simulação de pedestres, a maioria dos modelos é especificada para analisar e gerar previsões sobre o comportamento global de um grupo de pedestres frente a situações de evacuação e interação de multidões (ASHIDA *et al.*, 2001; TEKNOMO, ; HAMAGAMI; HIRATA, 2003; LERNER *et al.*, 2009).

Um bom modelo de fluxo de pedestres precisa ser capaz de simular o comportamento humano diante de diversas situações, preservando as características essenciais do mundo real, por exemplo as características comportamentais e psicológicas dos pedestres, de modo que os resultados da simulação gerada por este modelo sejam iguais ou semelhantes àqueles do sistema original modelado.

Para a construção do modelo proposto neste trabalho, um levantamento bibliográfico na área de dinâmica de multidões, psicologia social, pânico e comportamento coletivo será realizado para que seja possível utilizar variáveis psicocomportamentais. A análise crítica e processamento destas informações, verificando-se tendências sobre a movimentação de pedestres em situações de estresse definirão a estrutura do modelo.

Para o processo de modelagem de agentes autônomos que seguem comportamentos similares aos comportamentos humanos, será necessário o estabelecimento de premissas, já que os estudos psicológicos mostram tendências, mas raramente quantificam os fenômenos. Essas premissas serão traduzidas computacionalmente em linguagem probabilística, que aliadas a inteligência artificial representarão as variáveis psicocomportamentais que se deseja simular. Essas mesmas variáveis psicocomportamentais serão inspiradas nos estudos da pesquisadora Angela Behrendt (2011), que vem pesquisando há alguns anos o comportamento humano e avalia esse comportamento em grupos de pessoas em empresas, sendo que, recentemente (2013)

realizou uma avaliação comportamental sobre a necessidade de evacuação de pessoas em uma usina hidrelétrica. Além da pesquisa de Behrendt, outras bibliografias conhecidas no meio científico sobre comportamento de multidões como os estudos de Gustave Le Bon (2012), Quarantelli (1957), Turner e Killian (1972) servirão de base para a análise dos resultados.

A aplicação de métodos computacionais para atingir a programação utilizada não será o grande alvo desta pesquisa, pois o foco são os processos de modelagem e meios de simular situações que ocorram num processo de evacuação.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

O objetivo deste trabalho é desenvolver uma modelagem computacional com visualização tridimensional (3D), utilizando inteligência artificial através da geração de *i-plans* bidimensionais, que seja capaz de simular, em função de hipóteses simplificadoras, a movimentação de pessoas em situações de estresse, em ambientes fechados quaisquer, de forma a contribuir com as pesquisas recentes na área de movimentação pedonal, inovando com a implementação de variáveis psicocomportamentais.

1.1.2 Objetivo Específico

1. Desenvolver um simulador de movimentação de pedestres, levando em consideração a existência de variáveis psicocomportamentais que alimentam o modelo proposto.
2. Modelar o comportamento de agentes autônomos com níveis de estresse perante situações de evacuação.
3. Testar a hipótese da existência de quatro personalidades que dividem o comportamento dos seres humanos.
4. Comparar os resultados obtidos utilizando-se a hipótese da existência de quatro personalidades, com as tendências de comportamento observadas por outros autores em multidões que apresentam algum nível de estresse.
5. Validar os resultados qualitativamente através das tendências já descritas e quantitativamente através dos números obtidos com relação a tempos de evacuação, distâncias percorridas e escolha de portas de saída.

1.2 JUSTIFICATIVA

Com o crescimento das cidades, o fluxo de pedestres em ambientes como edifícios, passarelas, cinemas, teatros, centros de entretenimento, etc. tem aumentado desproporcionalmente ao espaço dos ambientes por onde estes pedestres circulam. Analogias entre tráfego de veículos e pedestres são realizadas frequentemente tal como sugere o *Highway Capacity Manual*¹ (ACADEMIES, 2000), sendo que a grande maioria dos simuladores de tráfego criados para representar o tráfego de veículos acabam sendo usados para modelar o fluxo de pedestres, deixando muitas brechas com relação a este último.

Muitos trabalhos sobre dinâmica de pedestres têm sido desenvolvidos nas últimas décadas (HELBING; MOLNÁR, 1995; DAAMEN; HOOGENDOORN; BOVY, 2005; TOYAMA, 2006; VENUTI; BRUNO, 2007; SCHADSCHNEIDER; SEYFRIED, 2009; PORTZ; SEYFRIED, 2010), mas o comportamento humano ainda não foi caracterizado com a devida complexidade que as situações de multidões muito densas e com altos níveis de estresse necessitam. Além disso, essas multidões muito densas, como passeatas, peregrinações, torcidas em jogos esportivos, podem representar comportamentos caóticos e turbulentos em relação a situações cotidianas. Por estes motivos, a simulação de pedestres tem se tornado ferramenta de grande importância, que pode explicitar e prever catástrofes, evitando assim transtornos decorrentes do planejamento e infraestrutura inadequados, possibilitando a garantia da segurança e o conforto dos pedestres em diversos tipos de ambientes.

O estudo de situações que envolvem multidão, quando associado à simulação, pode descrever e até prognosticar acontecimentos envolvendo a segurança pública, evitando assim transtornos decorrentes do planejamento e infraestrutura inadequados, e possibilitando descrever o comportamento humano diante de algumas situações.

Assim, trabalhar com inteligência artificial, utilizando para isso o Python, que é uma ferramenta computacional de livre acesso e fácil manipulação, transforma este trabalho em ferramenta de utilidade para a avaliação de espaços públicos e privados e movimentação de pedestres em diferentes condições.

¹ O Highway Capacity Manual (HCM) é uma publicação do Transportation Research Board (TRB), nos Estados Unidos. O HCM tem sido uma referência mundial para o transporte e também para os estudiosos e profissionais da área de engenharia de tráfego.

1.3 CONTRIBUIÇÕES DA TESE

A maior contribuição deste trabalho está na metodologia de modelagem da movimentação de pedestres assumindo variáveis psicocomportamentais, através da criação de uma ferramenta que simula a movimentação pedonal em situações de estresse, com ambientes fechados quaisquer, acoplada com a hipótese de existência de quatro personalidades que representam o comportamento psicossocial humano de uma forma generalizada.

1.4 ORGANIZAÇÃO DO TEXTO

O texto está organizado da seguinte forma: Capítulo 2 são apresentadas as referências bibliográficas pertinentes ao tema. No Capítulo 3 apresenta-se as teorias utilizadas para a formulação dos agentes BDI, dos *i-plans*, das variáveis psicocomportamentais e das curvas de Bézier que definem a movimentação dos agentes. No Capítulo 4 descreve-se os métodos utilizados para a formulação da modelagem computacional com visualização tridimensional (3D), utilizando inteligência artificial através da geração de *i-plans* bidimensionais. O Capítulo 5 traz os resultados obtidos com a modelagem. O Capítulo 6 contém discussões sobre os resultados e as inovações apresentadas. O Capítulo 7 traz as conclusões e o Capítulo 8 refere-se ao trabalhos que podem ser desenvolvidos futuramente baseando-se nesta pesquisa.

2 REVISÃO BIBLIOGRÁFICA

Na década de trinta, surgiram na Inglaterra as primeiras tentativas de sinalização para pedestres. Desde os anos sessenta muitos estudos têm sido dedicados para a determinação de um modelo matemático que vincule a velocidade das caminhadas com a densidade das multidões. Nos anos recentes, pesquisas foram dirigidas para o estudo de padrões de fluxo de multidões sob situações de emergência (KERNER, 2004), e uma crescente atenção foi dedicada aos efeitos do comportamento das multidões na dinâmica de estruturas no campo da engenharia civil (DAAMEN; BOVY; HOOGENDOORN, 2002; DAAMEN; HOOGENDOORN; BOVY, 2005; LEBACQUE; KHOSHAYARAN, 2005). Um grande número de fatores podem afetar o comportamento dos pedestres (idade, cultura, gênero, propósito da viagem, tipo de infraestrutura, direção da caminhada). Desta forma, as propriedades dos pedestres diferem de caso para caso, consequentemente suas características específicas não podem ser consideradas constantes no sistema.

Analisando as questões referentes ao espaço físico, pode-se perceber que, tratando-se de meios susceptíveis a um alto fluxo de pessoas, é comum ocorrerem aglomerações, principalmente em locais públicos. Os casos de aglomeração, ou "multidão", são pontuados por envolverem um alto número de indivíduos com características distintas num mesmo ambiente. Nesses casos, além da interação entre pedestre e meio, tem-se também a interação entre pedestres. Diversas situações são marcadas pelo estudo do comportamento de multidões, tais como a simulação de multidões aplicadas em produções cinematográficas, jogos digitais, planejamento de construções, evacuação de ambientes complexos, arquitetura, dentre outras (BICHO, 2009; DAPPER, 2007).

Em um espaço físico, o deslocamento de um pedestre descreve uma trajetória, que pode ser interferida por questões comportamentais ou físicas. De acordo com Bicho (2009) a modelagem e simulação de multidões caracterizadas por um alto fluxo populacional são temas de estudo em diferentes áreas da ciência, pois garantem um vasto campo aplicativo no que tange ao fluxo de pedestres. Nas últimas décadas, destacam-se os estudos relacionados à simulação de multidões, buscando responder questões associadas desde a escolha de um caminho, até a simulação de situações marcadas pelo pânico (ZAMPIERI, 2006). Esse estudo encontra-se diretamente relacionado ao aumento do fluxo populacional em certas regiões, despertando estudos específicos para esse novo comportamento.

Schadschneider (2002), Burstedde (2002) e colaboradores desenvolveram em 2002, um modelo de autômato celular estocástico para simulação de dinâmica de pedestres. Este baseia-se em um autômato celular¹ estocástico bi-dimensional. O modelo permite uma simulação rápida de grandes multidões, reproduzindo características coletivas e de auto-organização de dinâmica de pedestres, tais como formação de filas, fluxos em corredores e oscilações de fluxos encontrados em portas. Entretanto, para manter o modelo simples, os pedestres são providos apenas de uma inteligência mínima para a formação de estruturas complexas e efeitos de auto-organização observados em dinâmica de pedestres, o que muitas vezes, impede que este represente bem sistemas reais.

Toyama (2006), em sua dissertação de mestrado "Uma abordagem Multiagentes para a Dinâmica de pedestres", propôs a análise de um modelo que caracteriza o comportamento macroscópico de uma multidão, por meio da análise de certas variáveis, tais como, gênero, velocidade, conhecimento do ambiente e comportamento do grupo. Ainda nesse trabalho, Toyama apresenta um modelo baseado em sistemas multiagentes, propondo uma melhoria *Walker* para o modelo estocástico já existente criado por Schadschneider.

Ainda no campo de simulação pedonal, o trabalho de Helbing (2000), apresenta um modelo contínuo de pedestres baseado em forças generalizadas, caracterizado por simplicidade e robustez em relação a variações dos parâmetros, apropriado para situações que envolvam pânico. Nesse trabalho há algumas observações do fenômeno de pânico são realizadas, tais como:

- Variação e aumento da velocidade normal;
- Interações físicas;
- Ausência de coordenação dos movimentos;
- Entupimentos e aglomerações nas saídas;
- Danos à estrutura física do ambiente;
- Pisoteamentos. A caminhada (fuga) é retardada por pessoas caídas ou feridas se transformando em "obstáculos";

¹Um autômato celular é um modelo discreto estudado na teoria da computabilidade, matemática, e biologia teórica. Consiste de uma grelha finita e regular de células, cada uma podendo estar em um número finito de estados, que variam de acordo com regras determinísticas. A grelha pode ser em qualquer número finito de dimensões. O tempo também é discreto, e o estado de uma célula no tempo t é uma função do estado no tempo $t - 1$ de um número finito de células na sua vizinhança. Essa vizinhança corresponde a uma determinada seleção de células próximas (podendo eventualmente incluir a própria célula). Todas as células evoluem segundo a mesma regra para atualização, baseada nos valores das suas células vizinhas. Cada vez que as regras são aplicadas à grelha completa, uma nova geração é produzida.

- Tendência de “comportamento de massa”, ou seja, repetir o comportamento de outras pessoas;
- Ineficiência ou ignorância de saídas alternativas presentes em situações de fuga.

Essas observações podem ser representadas na simulação. O modelo contínuo de Helbing é considerado promissor, entretanto ainda apresenta falhas, por não ser possível representar muitas variáveis comportamentais, devido à dificuldade de obtenção de resultados ao se resolver as equações diferenciais parciais que o compõem. Assim os parâmetros utilizados por Helbing ainda geram resultados contra-intuitivos e muito diferentes do que ocorre na realidade.

Zampieri (2006) expõe um modelo estimativo de movimento de pedestres baseado em sintaxe espacial, medidas de desempenho e redes neurais artificiais. Nesse trabalho destaca-se a importância do estudo do comportamento de pedestres. Pensando no comportamento, o autor propõe um modelo baseado em redes neurais artificiais, que estabelece a relação entre o fluxo de pedestres e as propriedades do espaço urbano.

O trabalho de Dapper (2007) apresenta um planejamento de movimento para pedestres utilizando campos potenciais. Afirmando que o comportamento de cada pedestre, ou agente, é definido por uma alteração de seu campo potencial individual. As alterações dinâmicas do padrão podem ser alteradas em cada passo da simulação. Assim, podem ser evitadas colisões com obstáculos móveis ou combinar a complexidade dos movimentos. Em ambos os trabalhos, não existe o estabelecimento de um nível de estresse, sendo trabalhado apenas com situações mais simples referentes ao comportamento humano.

De acordo com Hughes (2002), o movimento dos pedestres é regido por equações de fluxo contínuo derivadas do fluxo de um único pedestre ou de múltiplos pedestres. O autor divide o fluxo de pedestres em dois tipos de regime: um regime de alta densidade, também chamado de regime subcrítico² e um regime de baixa densidade, que se denomina de supercrítico³. As teorias de Hughes derivam da ideia de se relacionar o fluxo e a densidade de pedestres através de um diagrama, conhecido como diagrama fundamental. Muitos outros autores também consideram tal diagrama como peça importante para a análise do fluxo de pedestres, como Fruin (1971), Tanaboriboon (1986), Weidmann (2006), Virkler (1994), Older (1968), Sarkar (1997) e Schadschneider (2009). Algumas teorias também baseadas em equações de fluxo contínuo se baseiam na existência dos diagramas fundamentais (HELBING; KELTSCH; MOL-

²Um fluxo de alta densidade sempre preenche o espaço (ambiente de caminhada) disponível

³Um regime de baixa densidade pode preencher o espaço disponível, ou se auto limitar para cada tipo de pedestre, dependendo da localização das fronteiras.

NáR, 1997; HOOGENDOORN; BOVY, 1999; HOOGENDOORN, 2003).

Na década de 90, o governo dos EUA financiou um dos mais intensivos estudos sobre evacuação de pessoas em edifícios. O atentado ao edifício World Trade Center em 26 de fevereiro de 1993, anterior ao atentado que culminou na derrubada do edifício, foi estudado exaustivamente por Fahy e Proulx (1995) utilizando como ferramentas de pesquisa entrevistas e questionários relacionados com o comportamento de ocupantes selecionados (VALENTIN; ONO, 2006).

Levando em consideração as ações e comportamentos humanos, com ou sem níveis de estresse, é visto que há possibilidade de associá-los a modelos matemáticos, ou simulações computacionais onde a obtenção de resultados satisfatórios para a análise de multidões é uma realidade.

A proposta desta pesquisa é a de criar uma metodologia de modelagem da movimentação de pedestres, acoplando inteligência artificial à variáveis psicocomportamentais com hipóteses simplificadoras, de forma que os resultados obtidos contribuam para a evolução da pesquisa em movimentação pedonal, suprimindo a ainda faltante utilização da parte psicossocial humana nesse tipo de simulação.

3 FUNDAMENTAÇÃO TEÓRICA

Muitas ferramentas matemáticas e computacionais, além da fundamentação proposta para as variáveis psicossociais, precisarão ser utilizadas. Desta forma, o embasamento teórico necessário para estas abordagens serão desenvolvidos neste capítulo.

3.1 INTELIGÊNCIA ARTIFICIAL

Embora a área de Inteligência Artificial (AI) seja estudada academicamente desde os anos 50, só recentemente tem gerado maior interesse pelo surgimento de aplicações comerciais, industriais e educacionais e não puramente acadêmicas. Um fator decisivo para o sucesso desta transição (da academia para a indústria) são os enormes avanços tecnológicos e computacionais ocorridos nas últimas duas décadas.

O primeiro programa computacional baseado em conhecimento, ou seja, baseado em uma lógica de programação mais elaborada, levando em consideração o comportamento humano, foi escrito em 1967 por Ed Feigenbaum, em Stanford. O programa intitulado DENDRAL (Dendritic Algorithm) (BUCHANAN; FEIGENBAUM, 1978) podia prever as estruturas de compostos químicos desconhecidos baseando-se em análises de rotinas. O programa MYCIN (SHORTLIFFE, 1976) foi desenvolvido logo após o DENDRAL, também por Feigenbaum, acompanhado de Buchanan e Edward Shortliffe. Esse sistema especialista foi desenvolvido para identificar as bactérias causadoras de infecções graves, tais como bacteremia e meningite, e para recomendar antibióticos, com a dose ajustada para o peso corporal do paciente. Seu nome derivou dos mesmos antibióticos, uma vez que muitos antibióticos contêm o sufixo “-mycin”. O sistema Mycin também foi utilizado para o diagnóstico de doenças da coagulação sanguínea, ou seja, o MYCIN era capaz de deduzir regras (RHEINGOLD, 2012).

Desde então, muito se tem estudado sobre AI e muitas controvérsias ocorrem em torno deste tema, principalmente no que diz respeito a definição do termo “inteligência”. Por essa razão, a Inteligência Artificial foi, e continua sendo, uma área que dispõe de múltiplas interpretações. Esse caráter múltiplo levou a pesquisa e desenvolvimento em AI a fixar-se em torno de três tipos principais de atividades (BITTENCOURT, 2006).

1. Desenvolvimento de modelos formais para a inteligência humana, tema da ciência cognitiva, também chamada psicologia computacional;

2. Desenvolvimento de aplicações educacionais, comerciais ou industriais utilizando técnicas de AI;
3. Exploração e experimentação de técnicas computacionais que apresentem potencial para a simulação do comportamento inteligente, a chamada AI básica.

Dentre essas três atividades, este trabalho percorrerá caminhos entre o segundo e terceiro itens, tendo como respaldo conhecimentos psicológicos referentes ao primeiro item.

Os conceitos básicos da AI podem ser divididos em diversos ramos que incluem: aprendizagem de máquina, raciocínio probabilístico, robótica, processamento de linguagem natural.

De acordo com Sebastian Thrun, professor de Ciência da computação na universidade de Stanford, AI é a disciplina que aborda a incerteza e a gerência no processo de tomada de decisão em ferramentas de *software* (THRUN; NORVIG, 2011). Essa definição de Thrun se encaixa na proposta desta tese.

3.1.1 Conceitos de Inteligência Artificial - AI

Muitas aplicações e técnicas podem ser citadas quando se fala de AI, por exemplo: planejamento automatizado, jogos, diagnósticos, planejamento logístico, robótica, redes neurais, sistemas com visão computacional, aplicações utilizando vida artificial, sistemas baseados na ideia de agentes artificiais (denominados Sistemas Multiagentes).

Este trabalho coloca seu foco sobre Sistemas Multiagentes (MAS - *Multi-Agent System*). Estes têm se tornado comuns para a resolução de problemas complexos (WOOLDRIDGE, 2002) como, telecomunicações (SOUZA; NETTO, 2012), monitoração de usinas nucleares (GUIMARÃES, 2006), controle de tráfego aéreo (DIB; CARDOSO; WEIGANG, 2005), simulação de pedestres (TOYAMA, 2006), etc.

Os MAS formam uma subárea da AI e concentram-se no estudo de agentes autônomos em um universo multiagente. Para os MAS, o termo autônomo designa o fato de que os agentes têm uma existência própria, independente da existência de outros agentes (REIS, 2003). Usualmente, cada agente possui um conjunto de capacidades comportamentais que definem sua competência, um conjunto de objetivos e a autonomia necessária para utilizar suas capacidades comportamentais a fim de alcançar seus objetivos. Um agente é uma entidade computacional com um comportamento autônomo que lhe permite decidir suas próprias ações (ALVARES; SICHMAN, 1997). A decisão de qual ação deve ser executada é determinada pelo agente, tendo em con-

sideração as mudanças que ocorrem no ambiente no qual atua e o desejo de alcançar seus objetivos. A ideia principal em um sistema multiagente é que um comportamento global inteligente pode ser alcançado a partir do comportamento individual dos agentes, ou seja, o comportamento macroscópico emerge do comportamento microscópico. Dessa forma, pode-se definir um agente autônomo (ativo ou inteligente) como um “ser” capaz de perceber seu ambiente por meio de sensores e agir sobre esse ambiente através de atuadores. Pode-se traçar um paralelo desse processo através de um agente humano, onde este usa seus órgãos sensitivos como sensores, e mãos, pernas e outras partes do corpo como atuadores. Na robótica, os atuadores podem ser as câmeras, detectores infravermelhos, etc. Em um agente de *software* os atuadores são teclado, arquivos, pacotes da rede, vídeos, impressora, dentre outros.

A arquitetura de um agente é então formada dessa maneira: com sensores e atuadores. Os sensores detectam o ambiente avaliando as situações e os atuadores reagem de acordo com a tarefa que lhe foi ensinada ao encontrar determinada situação. Por exemplo: um agente humano analisa o ambiente através de seus olhos (sensores) e detecta um buraco. As pernas (atuadores), precisam estar programadas para desviar desse buraco, ou pulá-lo, etc.

Uma ação de um agente inteligente é composta por uma sequência de percepções e não apenas uma percepção por vez. A escolha da ação a ser tomada dependerá da análise dessa sequência armazenada. Além disso, um agente só poderá ser considerado inteligente se obtiver sucesso em suas ações, ou seja, o seu desempenho necessita ser o desempenho máximo procurado ao ser programado. Exemplo: o desempenho de um agente aspirador de pó pode ser a quantidade de sujeira limpa, tempo total gasto, quantidade de eletricidade consumida, quantidade de barulho gerado, etc (NORVIG; RUSSELL, 2004).

Assim pode-se definir que um agente inteligente possuirá armazenada uma sequência de percepções. A partir destas, ele deverá selecionar uma ação que maximize seu desempenho de acordo com as evidências fornecidas pela sequência e por qualquer conhecimento interno do agente. Essa maximização de desempenho é também chamada de desempenho ótimo ou otimizado.

A coleta de informações, ou seja, explorar um ambiente desconhecido, é um passo fundamental da inteligência. Por exemplo, analisar se o café está quente antes de bebê-lo maximizará a resposta de saborear sem se queimar, ou ainda olhar antes de atravessar a rua maximizará o desempenho de atravessar sem ser atropelado. Um agente inteligente deve ser capaz de operar com sucesso em uma grande quantidade de ambientes, dado um tempo suficiente para se adaptar, pois tem a capacidade de reconhecer e se adaptar a novas condições (FERREIRA, 2012).

É necessário saber que tipo de ambiente se está especificando no programa para que esse agente possa se movimentar. Por exemplo:

- O ambiente é totalmente observável, parcialmente observável ou totalmente desconhecido? Analisa-se o ambiente quanto ao acesso completo do estado desse, fornecido pelos sensores.
- O ambiente é discreto ou contínuo? Verifica-se se as percepções e ações são contáveis e distintas.
- O ambiente é determinístico ou estocástico? Analisa-se se o estado do ambiente é totalmente determinado pelas ações selecionadas pelo agente ou possui ações aleatórias.
- O ambiente é estático ou dinâmico? O ambiente se altera com as ações do agente?
- O ambiente é episódico ou sequencial? A experiência do agente é dividida em episódios, ou considera-se um único episódio.
- Trabalha-se com um único agente ou múltiplos agentes? Ambientes com múltiplos agentes necessitam de formas de comunicação.

A partir dessas definições é possível determinar uma heurística¹ de movimentação para os agentes. Referente a essa movimentação, frequentemente precisa-se lidar com conhecimentos probabilísticos em que a base de informações é incompleta, inexata, imparcial ou até mesmo ambígua para que o agente consiga tomar suas decisões. Desta forma, será usada neste trabalho uma junção de conhecimento simbólico (via agentes com crenças, desejos e intenções, que será melhor explicado nas seções a seguir) e probabilístico, em especial, probabilidades estruturadas usando redes bayesianas². Além disso, os agentes não têm conhecimento de todo o ambiente, apenas dos espaços que podem ser detectados por seu cone de visão (ver Sec. (4.2.3)), assim define-se que este será parcialmente observável. Também será um ambiente contínuo, pois o agente tem liberdade de movimento em qualquer direção; estático, pois não se altera com as ações do agente; estocástico³ pois contará com algumas

¹ Define-se procedimento heurístico como um método de aproximação das soluções ideais dos problemas. A heurística assume uma solução próxima da ideal baseada em uma função de avaliação do resultado.

² Define distribuição de probabilidade sobre grafos ou variáveis aleatórias

³ Padrões estocásticos são aqueles que têm origem em processos não determinísticos, com origem em eventos aleatórios. Dentro da inteligência artificial, programas estocásticos trabalham usando métodos probabilísticos para solucionar problemas, como em redes neurais estocásticas, otimização estocástica e algoritmos genéticos. Um problema pode ser estocástico em si mesmo, como no planejamento sob incerteza.

decisões aleatórias e probabilísticas (o que justifica o uso de redes bayesianas); episódico, pois as várias percepções do ambiente, ao longo do tempo, vão alimentar novos planos e de múltiplos agentes para que seja possível representar conceitos de movimentação em grupo.

3.2 MODELOS PROBABILÍSTICOS

As redes bayesianas (BN - Bayes Network) são modelos de representação do conhecimento que trabalham com o conhecimento incerto e incompleto por meio da Teoria da Probabilidade Bayesiana, publicada pelo matemático Thomas Bayes em 1763. As BN foram aperfeiçoadas no início dos anos 80 para facilitar a tarefa de predição em sistemas de inteligência artificial (PEARL, 1988). BN, também conhecidas como redes de opinião, redes causais, gráficos de dependência probabilística, são modelos gráficos para raciocínio (conclusões) baseado na incerteza, onde os nós representam as variáveis (discreta ou contínua), e os arcos representam a conexão direta entre eles (KORB; NICHOLSON, 2004). Desta forma, uma BN é constituída por: um conjunto de variáveis e um conjunto de arcos ligando as variáveis; cada variável possui um conjunto limitado de estados mutuamente exclusivos; as variáveis e arcos formam um grafo dirigido, sem ciclos⁴, como apresentado na Fig. (1).




FIGURA 1: Grafos Dirigidos Acíclicos.

Pode-se também definir uma BN matematicamente usando uma representação compacta de uma tabela de conjunção de probabilidades do universo do problema. Assim, seja R uma variável aleatória com n estados e $P(R)$ a distribuição de probabilidade para estes estados.

$$P(R) = (a_1, \dots, a_n)$$

⁴Grafos dirigidos acíclicos são aqueles onde, para qualquer vértice v , não há nenhuma ligação dirigida começando e acabando em v .

onde a_i é a probabilidade de R estar no estado a_i . Se a variável T possui m estados, (b_1, \dots, b_m) , então $P(R/T)$ representa uma tabela $n \times m$ contendo valores $P(a_i/b_i)$, como pode ser observado no exemplo da Tab. (1).

	b_1	b_2	\dots	b_m
a_1	0,07	0,05	\dots	0,08
a_2	0,04	0,04	\dots	0,05
\vdots	\vdots	\vdots	\ddots	\vdots
a_n	0,06	0,03	\dots	0,09

TABELA 1: Tabela de Conjunção de Probabilidades

Os conceitos da Teoria das Probabilidades para o embasamento da AI podem ser obtidos nos mais diversos livros de estatística. Recomenda-se ver (JAMES, 1996), (FERNANDEZ, 2011), (MAGALHÃES, 2011), onde é possível relembrar teorias como: Teorema de Bayes, Teorema da Probabilidade Total, Variáveis Aleatórias, Funções de Distribuição.

As BN são parte da construção da Inteligência Artificial, pois englobam conceitos como: Algoritmos de Filtragem (filtros de partículas e filtros de Kalman), Modelos ocultos de Markov (HMMs - Hidden Markov Models), Processos de decisão de Markov (MDPs - Markov Decision Processes), Processos de Decisão de Markov Parcialmente Observável (POMDPs - Partially Observable Markov Decision Processes); que são ferramentas probabilísticas (NORVIG; RUSSELL, 2004).

O conceito de Cadeias de Markov, também presente nas bibliografias sugeridas acima, uma vez que será apresentado a seguir, será muitas vezes citado e discutido dentro da teoria sobre AI. Para isso, inicialmente será definido o que são Processos Estocásticos. Assim,

Definição 3.2.1. (NOGUEIRA, 2012) *Um processo estocástico é definido como uma coleção de variáveis aleatórias $X(t)$ indexadas por um parâmetro t pertencente a um conjunto T , que pode ser tomado pelos conjunto dos inteiros não-negativos.*

Um Processo Estocástico é dito Processo de Markov se o estado futuro deste só depende do estado presente, e não dos estados passados. Matematicamente pode-se escrever

$$\begin{aligned}
 &P(X(t_{k+1}) \leq x_{k+1} / X(t_k) = x_k, X(t_{k-1}) = x_{k-1}, \dots, X(t_1) = x_1, X(t_0) = x_0) = \\
 &= P(X(t_{k+1}) \leq x_{k+1} / X(t_k) = x_k), \\
 &\text{para } t_0 \leq t_1 \leq \dots \leq t_k \leq t_{k+1} = 0, 1, \dots \text{ e toda sequência } k_0, k_1, \dots, k_{t-1}, k_t, k_{t+1}
 \end{aligned} \tag{1}$$

As probabilidades condicionais são denominadas probabilidades de transição. Assim, pode-se denotar a probabilidade de transição como a probabilidade de X_{n+1} ⁵ estar no estado j dado que X_n está no estado i ou seja

$$P_{ij}^{n,n+1} = P(X_{n+1} = j / X_n = i). \quad (2)$$

A análise de uma Cadeia de Markov caracteriza-se principalmente pelo cálculo das probabilidades de transições em n passos, portanto P_{ij}^n é denotado por (NOGUEIRA, 2012)

$$P_{ij}^n = P(X_{m+n} = j / X_m = i). \quad (3)$$

Podem-se representar as quantidades P_{ij}^n de forma matricial. Tal notação é importante, pois torna o processo mais simples de ser representado computacionalmente. Dessa forma denota-se a matriz de Markov ou matriz de Probabilidades de Transição da seguinte forma:

$$||P_{ij}^n|| \quad \text{desde que} \quad \begin{cases} \sum_{k=0}^{\infty} P_{ik} P_{kj}^{n-1} \\ P_{ij}^0 = \begin{cases} 1 & \text{se } i = j \\ 0 & \text{se } i \neq j \end{cases} \end{cases} \quad (4)$$

Proposição 3.2.1. *Um Processo de Markov está completamente definido quando sua matriz de probabilidades de transição e seu estado inicial X_0 (ou, mais genericamente, a distribuição de probabilidade de X_0) estão especificados. (UFPE, 2012)*

Pela iteração da Eq. (4), obtém-se:

$$\mathbf{P}^{(n)} = \underbrace{\mathbf{P} \mathbf{x} \mathbf{P} \mathbf{x} \mathbf{P} \dots \mathbf{x} \mathbf{P}}_{n \text{ VEZES}} \quad (5)$$

Demonstração. O evento de ir do estado i para o estado j em n transições pode ser realizado por caminhos mutuamente exclusivos, indo para um estado intermediário k ($k = 0, 1, \dots$), na primeira transição, e então ir do estado k ao estado j nas $(n - 1)$ transições restantes. Pela propriedade de Markov, a probabilidade da segunda transição é $P_{kj}^{(n-1)}$ (da primeira transição é, obviamente, P_{ik}) (UFPE, 2012). Usando a

⁵ X_n está no estado i se $X_n = i$

Lei da Probabilidade Total:

$$\begin{aligned}
 P_{ij}^{(n)} &= P\{X_n = j | X_0 = 1\} = \sum_{k=0}^{\infty} P\{X_n = j, X_1 = k | X_0 = i\} \\
 &= \sum_{k=0}^{\infty} P\{X_1 = k | X_0 = i\} \cdot P\{X_n = j | X_0 = i, X_1 = k\} \\
 &= \sum_{k=0}^{\infty} P_{ik} P_{kj}^{(n-1)}
 \end{aligned}$$

□

3.2.1 Métodos ocultos de Markov

Os Métodos ocultos de Markov (HMM) foram descritos pela primeira vez ao final dos anos 60 (BAUM; PETRIE, 1966). São usados para analisar ou prever séries temporais⁶. O HMM é um processo estocástico não visível (por isso o nome “oculto”), mas que pode ser observado através de outro processo estocástico que produz a sequência de observações. Por este motivo pode ser considerado um processo duplamente estocástico (RABINER, 1989).

Os processos ocultos consistem de um conjunto de estados conectados por transições com probabilidades (autômato finito), enquanto os processos observáveis (não escondidos) consistem de um conjunto de saídas ou observações, cada qual podem ser emitidos por cada estado de acordo com alguma saída da Função Densidade de Probabilidade, PDF (MORITA, 1998).

Seja uma sequência de estados que evoluem no decorrer do tempo e cada estado depende apenas do estado anterior na rede bayesiana, então cada estado é constituído do que se chama de medida. Essa rede bayesiana é o núcleo dos HMMs, e de vários filtros probabilísticos, como filtros de Kalman e filtros de partículas.

Pode-se dizer que os estados evoluem por uma cadeia de Markov. Isso quer dizer que cada estado depende apenas do seu antecessor, mas o que transforma isso em um modelo oculto de Markov é o fato de existirem variáveis de medida que caracterizam estes estados. Logo, em vez de se observar os estados, precisa-se analisar essas medidas. Ferramentas como máxima verossimilhança e suavização laplaciana podem ser usadas neste contexto.

Os HMMs são usados em duas situações principais:

1. Predição: Espera-se prever o próximo estado, ou prever a próxima medida. As

⁶Em estatística, econometria, matemática aplicada e processamento de sinais, uma série temporal é uma coleção de observações feitas sequencialmente ao longo do tempo

equações para predição são baseadas em probabilidade total.

2. Estimativa de Estados: Deseja-se calcular a probabilidade de um estado interno ou oculto, dadas as medidas. As equações para estimar estados são baseadas no Teorema de Bayes.

No contexto de HMMs, “filtragem” refere-se à determinação da distribuição de uma variável latente em um momento específico, tendo em conta todas as observações até aquele momento, ou seja, faz-se uma filtragem das informações da variável para analisar o que pode continuar no processo e o que deve ser retirado ou modificado.

Dentre os conceitos probabilísticos citados até o momento, a inferência probabilística ou bayesiana é ferramenta fundamental, pois descreve as incertezas sobre quantidades invisíveis de forma probabilística, ou seja, computa a distribuição de probabilidade posterior, $P(A/B)$, para um conjunto de variáveis de consulta, A , dado uma evidência, B .

Castilho e Gutierrez (1997) classificam os algoritmos de inferência em três níveis: Exatos, Aproximados e Simbólicos. Nesse trabalho os algoritmos usados são classificados como Aproximados, pois esses utilizam técnicas distintas de simulação para chegar a valores aproximados das probabilidades. Como exemplo, podem-se citar os algoritmos de amostragem de Gibbs (Gibbs Sampling)⁷ e Máxima Verossimilhança⁸ com Suavização Laplaciana (MLLS - Maximum Likelihood Laplace Smoothing). O primeiro gera cada amostra baseado na configuração gerada pela amostra anterior e atualiza a configuração atual para amostras futuras. O algoritmo de Gibbs depende de uma configuração inicial. A estimativa do algoritmo é baseada na probabilidade da variável fazer a transição de um estado para outro, chamada de probabilidade de transição (FIORI; THIELE; RAMOS, 2012).

Quando estima-se a verossimilhança, utiliza-se como probabilidade o quociente do número de eventos específicos sobre o número total de eventos do conjunto (espaço amostral). Porém, ao se fazer isso, pode-se chegar a falsos resultados nulos. Para amenizar esse problema utiliza-se a suavização laplaciana. Assim, no algoritmo MLLS, o número de eventos específicos é acrescido de um valor k e normalizado adicionando-se k a toda classe (MANNING; RAGHAVAN; SCHÜTZE, 2008). Desta

⁷O amostrador de Gibbs é um algoritmo para gerar uma sequência de amostras da distribuição conjunta de probabilidades de duas ou mais variáveis aleatórias. O propósito de tal sequência é aproximar a distribuição conjunta, ou computar uma integral (tal como um valor esperado). A amostragem de Gibbs é um exemplo de um algoritmo Monte Carlo via cadeias de Markov.

⁸A verossimilhança (likelihood) é a interpretação da função de um parâmetro dado um resultado fixo, ou seja, indica qual a probabilidade de um valor de parâmetro em função do resultado observado. Segundo Bussab e Morettin (2004) o princípio da verossimilhança afirma que deve-se escolher o valor do parâmetro desconhecido que maximiza a probabilidade de obter a amostra observada, ou seja, o valor que torna a mostra o mais “provável”.

forma, a probabilidade que podia ser calculada da forma

$$P(X) = \frac{n(\text{eventos específicos})}{n(\text{Espaço Amostral})}, \quad (6)$$

passa a ser calculada por

$$P(X) = \frac{n(\text{eventos específicos}) + k}{n(\text{Espaço Amostral}) + k(x)}, \quad (7)$$

onde $n(X)$ representa o número de elementos de um conjunto. Desta forma estes dois algoritmos (Amostragem de Gibbs e MLLS) serão utilizados quando o processo de decisão dos agentes chegarem a situações críticas onde seja necessário o uso de ferramentas probabilísticas para a tomada de decisão.

Existem vários tipos de filtros bayesianos dentro dessa categoria, sendo que os principais são o Filtro de Kalman e o Filtro de Partículas.

Assim, o filtro de Kalman é um algoritmo para realizar, de forma eficiente, inferências exatas sobre um sistema dinâmico linear, que é um modelo Bayesiano semelhante a um HMM (HO; LEE, 1964), entretanto, nesta pesquisa necessita-se que as inferências sejam aproximadas e que seja possível trabalhar com distribuições além das gaussianas.

Thrun e Norvig (2011) aconselham o uso de filtros de partículas, também conhecidos como Métodos Monte Carlo via Cadeias de Markov (MCMC), quando o assunto é AI e mais especificamente agentes inteligentes em ambientes parcialmente observáveis.

3.2.2 Filtro de Partículas

A ideia do método Monte Carlo é escrever a integral que se deseja calcular como um valor esperado. Seja o problema de calcular a integral de uma função $g(\theta)$ no intervalo $(a; b)$, isto é:

$$J = \int_a^b g(\theta) d\theta. \quad (8)$$

A Eq. (8) pode ser reescrita como:

$$J = \int_a^b (b-a)g(\theta) \frac{1}{b-a} d\theta = (b-a)E(g(\theta)), \quad (9)$$

identificando θ como uma variável aleatória com distribuição uniforme $U(a, b)$ ⁹. Desta

⁹É uma distribuição de probabilidades contínuas onde a probabilidade de se gerar qualquer ponto em um intervalo contido no espaço amostral é proporcional ao tamanho do intervalo. Além disso, qualquer outra distribuição contínua, na qual a função distribuição acumulada seja invertível, pode ser simulada

forma, transforma-se o problema de avaliar a integral em um problema estatístico em que se deseja estimar uma média, $E[g(\theta)]$. Dispondo de uma amostra aleatória de tamanho n , $\theta_1, \dots, \theta_n$ da distribuição uniforme no intervalo $(a; b)$ tem-se também uma amostra de valores $g(\theta_1), \dots, g(\theta_n)$ da função $g(\theta)$ e a integral acima (9) pode ser estimada pela média amostral, ou seja,

$$\hat{f} = (b - a) \frac{1}{n} \sum_{i=1}^n g(\theta_i) \quad (10)$$

e verifica-se que

$$E(\hat{f}) = \frac{(b - a)}{n} \sum_{i=1}^n E(g(\theta_i)) = (b - a)E(g(\theta)) = \int_a^b g(\theta) d\theta. \quad (11)$$

A generalização é bem simples para o caso em que a integral é a esperança matemática de uma função $g(\theta)$ onde θ é uma função de densidade $p(\theta)$, ou seja

$$J = \int_a^b g(\theta) p(\theta) d\theta = E(g(\theta)). \quad (12)$$

Tendo no lugar de uma distribuição uniforme uma distribuição de valores $\theta_1, \dots, \theta_n$ para $p(\theta)$, pode-se calcular:

$$\hat{f} = \bar{g} = \frac{1}{n} \sum_{i=1}^n g(\theta_i). \quad (13)$$

Essa simplicidade do Método Monte Carlo fez com que seu desenvolvimento se desse com a necessidade de se resolverem problemas cada vez mais complexos, onde muitas vezes encontrar uma densidade que seja simultaneamente uma boa aproximação e fácil de ser amostrada seria quase impossível. Os conceitos de Cadeias de Markov foram acoplados ao método já existente. Essa junção deu origem ao Método Monte Carlo via cadeias de Markov (MCMC) ou também chamada de algoritmos sequenciais de Monte Carlo. A ideia continua a ser a de encontrar uma amostra da distribuição e calcular estimativas amostrais de características desta distribuição. A diferença é que para o MCMC usam-se técnicas de simulação iterativa, baseadas em cadeias de Markov, e assim os valores gerados não são mais independentes (JUSTINIANO, 2012).

O problema de filtragem é um caso particular dos métodos sequenciais de Monte Carlo. Ele consiste na estimação de um sinal desconhecido (oculto) a partir dos dados provenientes das observações que, por sua vez, são uma função aleatória dos sinais. O estimador é chamado de filtro. A amostragem por importância sequencial (SIS) (BATISTA, 2011) é um método Monte Carlo que forma as bases para a maior parte

a partir da distribuição uniforme.

dos filtros sequenciais de Monte Carlo desenvolvidos nas últimas décadas (DOUCET; FREITAS; GORDON, 2001). Esta aproximação sequencial é conhecida por vários nomes como filtragem *bootstrap*, algoritmo de condensação, filtro de partículas ou o próprio MCMC já citado (CUPERTINO, 2007).

Os Filtros de Partículas (PFs - Particle Filters) são filtros que realizam estimação sequencial de Monte Carlo e guardam a densidade de probabilidade do estado do sistema na forma de partículas, podendo representar um número muito maior de distribuições, dispensando as condições de Gaussianidade e linearidade do modelo e ainda possuindo adequadas condições de convergência.

O filtro de partículas baseia-se na distribuição por importância a qual é definida como sendo a distribuição a priori. Infelizmente o processo degenera-se quando o tempo cresce, e não se consegue a distribuição a posteriori. Uma etapa adicional é acrescida para viabilizar o procedimento. Trata-se da amostragem com reposição repetidas vezes. As partículas amostradas que são pouco representativas dentro da distribuição são retiradas do processo e as partículas “sobreviventes” representam a distribuição. Esta mesma distribuição é usada como base para o prosseguimento do método em cada instante de tempo (AIUBE, 2005).

Thrun defende a ideia de que PF talvez seja o algoritmo que mais faz sucesso quando o assunto é AI.

Fazendo uma analogia entre a movimentação de agentes (pedestres) e a robótica, escolheu-se usar filtros de partículas neste trabalho, devido aos bons resultados obtidos por diversos autores quando refere-se a movimentação de robôs (FOX *et al.*, 2000; REKLEITIS, 2004; RENS; FERREIN; POEL, 2009).

3.3 PROCESSO DE MARKOV PARCIALMENTE OBSERVÁVEL

Nas seções anteriores deixou-se claro que o espaço de movimentação dos agentes é um ambiente parcialmente observável. A ferramenta escolhida para solucionar este tipo de problema, dentro da necessidade de uso de ferramentas probabilísticas, foi o Processo de decisão de Markov parcialmente observável (POMDP). Um ambiente totalmente observável é aquele onde é possível ver todo o ambiente e tomar decisões baseando-se na resposta imediata dos sensores. A necessidade de usar memória sensorial e de analisá-la antes de tomar as decisões mostra que o ambiente é parcialmente observável.

No POMDP o agente precisa se lembrar das ações que executou e das observações que percebeu ao longo do tempo e tentar usar essas informações para tomar a

próxima decisão. Ao invés do agente estudar o estado atual do sistema, estuda-se uma distribuição de probabilidade sobre os estados antes de tomar as decisões.

Os POMDPs podem ser usados para modelar diversos tipos de problemas como modelagem de comportamento em ecossistemas, diagnóstico médico (CASSANDRA; LITTMAN; ZHANG, 1997).

3.3.1 Descrição Matemática do Processo de Decisão de Markov Parcialmente Observável

Um POMDP é uma tupla $(S, A, T, R, \Omega, O, P)$, onde:

- a) S é um conjunto de estados em que o processo pode estar;
- b) A é um conjunto de ações que podem ser executadas em diferentes épocas de decisão;
- c) $T : S \times A \times S \mapsto [0, 1]$ é uma função que dá a probabilidade de o sistema passar para um estado $s' \in S$, dado que estava no estado $s \in S$ e a ação executada foi $a \in A$;
- d) $R : S \times A \mapsto \mathbb{R}$ é uma função que dá o custo (ou recompensa) por tomar uma decisão $a \in A$ quando o processo está em um estado $s \in S$;
- e) Ω é o conjunto de observações que são obtidas em cada período de decisão;
- f) $O : S \times A \mapsto \Pi(\Omega)$ é a função de observação que dá, para cada ação e estado resultante, uma distribuição de probabilidade sobre possíveis observações (escreve-se $O(s'; a; o)$ para a probabilidade de se fazer a observação o , dado que o agente tomou a ação a e acabou no estado s');
- g) P é uma distribuição inicial de probabilidades sobre o conjunto de estados.

Os conjuntos S, A e Ω serão considerados finitos. Ainda:

- h) z é denominado *Horizonte* de um POMDP, ou seja z é o número de decisões possíveis para a tomada de decisões. O horizonte pode ser finito (quando há um número fixo de decisões a tomar), infinito (quando a tomada de decisão é feita repetidamente) ou indefinido (semelhante ao horizonte infinito, mas com a possibilidade do processo parar se chegar a algum estado que tenha sido marcado como final).

- i) π são as políticas de decisão, ou regras de decisão. Uma regra de decisão para um POMDP em uma época de decisão k é uma função $d_k : S \rightarrow A$, que determina a ação a ser executada, dado o estado do sistema.

Uma política para um POMDP é uma sequência de regras de decisão $\pi = \{d_0, d_1, \dots, d_z\}$. Normalmente se quer encontrar uma política que otimize um dado critério de desempenho das decisões (PELLEGRINI, 2006).

Além dessas representações, ainda é necessário definir o estado de informações, C_k . Este é definido como a representação do conhecimento que se tem sobre o sistema no momento de se tomar uma decisão k . O estado de informações é composto por uma distribuição de probabilidade sobre os estados nos primeiros momentos de decisão, b_0 , e por um histórico completo de ações e observações, desde os primeiros momentos de observação e pode ser representado por $C_k = (b_0, a_0, o_0, a_1, o_1, \dots, a_{k-1}, o_{k-1})$. Dessa forma $C(P)$ é o espaço de todos os estados de informação para um POMDP. Pode-se dizer que um estado de informações é dividido em dois estados, o primeiro é representado por uma distribuição de probabilidade que representa o conhecimento do agente sobre os estados, o segundo é chamado de estado de crenças (belief). Este é representado por uma distribuição de probabilidades sobre os possíveis estados do sistema, ou seja, as crenças do agente sobre tal sistema. Para modificar um estado de informação representado desta forma é necessário adicionar o par $(a; o)$ com a última ação e a observação resultante.

Ainda é necessário que seja criado um estimador de estados de informação, τ , para uma boa representação dos estados de informação $C(P)$ em um POMDP. A cada época de decisão, o tomador de decisões verifica o estado de informação atual ($C(P)$), a última ação executada e a última observação obtida do ambiente. A partir desses dados, τ determina um novo estado de informação, que é usado como entrada para uma política π , que determina a próxima ação a ser tomada (PELLEGRINI; WAINER, 2007).

Desta forma, o conjunto de ações planejadas (políticas) deverá maximizar a função de recompensa (ou o retorno) acumulada ao longo do tempo ou minimizar a função de custo em todo o espaço possível. Uma política com tais características, ou seja, uma política ótima será representada por π^* . Em episódios finitos, caso deste trabalho, a função de recompensa pode ser simplesmente a soma das recompensas de cada instante de tempo, desde o instante inicial.

A representação para as funções ótimas podem ser dadas de diversas formas. Desde Redes Neurais (LIN; MITCHELL, 1992), Discretização (LOVEJOY, 1991; ROY, 2003) e Hiperplanos até Controladores (HANSEN; ZHOU, 2003) e Planos Condicionais (KAELBLING; LITTMAN; CASSANDRA, 1998).

A escolha para a representação se dá de acordo com as necessidades do trabalho. No caso deste, é mais coerente trabalhar com Controladores Estocásticos (POUPART; BOUTILIER, 2003), devido à necessidade da utilização de distribuições de probabilidade para a geração de cada ação de forma que estas possam minimizar os custos da caminhada, fazendo com que as políticas sejam quase ótimas.

Com esses conceitos definidos, fez-se a escolha por uma estrutura híbrida entre agentes BDI (Beliefs-Desires-Intentions - Crença-Desejo-Intenção) e POMDP (NAIR; TAMBE, 2005), para caracterizar os agentes até então citados com as necessidades impostas por este projeto (necessidades comportamentais específicas de seres humanos).

3.4 AGENTE BASEADO EM CRENÇA, DESEJO E INTENÇÃO

Agente BDI é um modelo filosófico proposto por Michael Bratman (1984). O próprio Bratman desenvolveu mais trabalhos nesta área como “Intention, Plans, and Practical Reason” (1987), mais recentemente “Intention, Belief, and Instrumental Rationality” (BRATMAN, 2009) e um artigo intitulado “Intention, Belief, Practical, Theoretical” presente no livro “Spheres of Reason: New Essays in the Philosophy of Normativity” (BRATMAN, 2010) dentre muitos outros. Todos na área de inteligência computacional.

Os agentes BDI são capazes de ações independentes e autônomas para atingir objetivos para os quais foram projetados (PEREIRA, 2008). De maneira geral, pode-se dizer que são agentes que decidem por si o que fazer; dada uma situação. Observa-se, entretanto, que esta é uma abordagem heurística, onde um agente BDI constrói um plano para realizar uma determinada intenção, tenta executá-lo e, se falha, precisa reconsiderar sua intenção ou formular outro plano e assim sucessivamente. Desta forma, seu comportamento é dado por tentativa e erro, geralmente impossibilitando um comportamento ótimo se comparado aos modelos de teoria da decisão¹⁰. Outro fator importante que influencia seu desempenho é a dinâmica do ambiente, que pode fazer com que o agente passe mais tempo reconsiderando suas intenções do que fazendo ações. Este balanço entre o tempo que o agente passa deliberando e o tempo que passa executando planos é fundamental para um bom agente BDI. Por outro lado, os POMDPs podem ser a abordagem ideal para problemas que se concentram na coordenação de sociedades de agentes e na existência de incerteza de

¹⁰ A teoria da decisão é uma ciência que trabalha com a tomada de decisões racionais e consistentes em situações de incerteza, fornecendo um conjunto de conceitos e técnicas para apoio do decisor. O objetivo da Teoria da Decisão é apoiar a escolha de uma ação (ou de uma estratégia) que seja consistente com as alternativas, a informação, os valores e a lógica do decisor no momento da tomada de decisão. O decisor é o responsável pela tomada de decisões. Pode ser um único indivíduo um grupo, uma empresa ou mesmo uma nação.

ações e observações em domínios do mundo real. A complexidade de se encontrar uma política ótima em modelos onde o espaço de estados seja muito grande algumas vezes é intratável, mas ainda parece ser uma das melhores soluções para este tipo de problema. Assim, a ideia de utilizar um algoritmo para construção de planos BDI baseados em políticas ótimas obtidas através de POMDPs encaixa-se à proposta deste trabalho.

O formalismo de um agente BDI baseia-se em um modelo de ramificação de tempo (EMERSON; HALPERN, 1986), no qual as variáveis opinião, desejo e intenção, são elas próprias estruturas de ramificação de tempo.

As crenças representam as informações que o agente tem sobre o mundo e sobre si próprio. Os desejos estão relacionados com os estados do ambiente que o agente eventualmente deseje atingir, no entanto, os desejos não precisam obrigatoriamente levar o agente a agir. O seja, os desejos são um conjunto de estados possíveis de onde o agente escolhe o que fazer. As intenções são caracterizadas por uma escolha de um estado a ser atingido e por um certo grau de comprometimento a esta escolha.

Um agente BDI usa uma “descrição BDI”. Essa descrição é definida como uma tupla $(S, A, T, B, D, I, Del, M)$, onde S , A e T são, respectivamente, o espaço de estados, o conjunto de ações e a função de transição e:

- a) B é o conjunto de crenças, D o de desejos e I o de intenções;
- b) Del é o componente de deliberação;
- c) M é o componente de raciocínio meio-fim.

Portanto considera-se que S , A e T são os mesmos para ambas as descrições (BDI e POMDP). Além disso, considera-se que B e P representam a mesma ideia, ou seja, identificam em que estado o agente se encontra.

Com estas equivalências definidas, tem-se de um lado recompensas e políticas, e de outro tem-se desejos, deliberação, raciocínio meio-fim, e intenções. Na verdade, como recompensas são meios de se determinar políticas, e desejos são um passo para se determinar intenções, estes componentes podem ser ignorados. Finalmente a relação que se considera com detalhes é a entre políticas e intenções.

Modelos híbridos têm sido propostos para combinar as vantagens e superar as desvantagens dos dois modelos, existindo diversas abordagens diferentes que mostram a relação entre BDI e POMDP e como eles podem ser combinados para tratar problemas de naturezas diversas (SIMARI; PARSONS, 2006; PARUCHURI *et al.*, 2006; NAIR; TAMBE, 2005). Por exemplo, um agente BDI com planos baseados em

POMDPs, ou um POMDP cuja política é construída a partir de planos BDI, têm sido apontados como soluções para melhorar o desempenho de agentes BDIs ou a tratabilidade de modelos POMDPs, respectivamente (SIMARI; PARSONS, 2006)

3.4.1 Agentes BDI a partir de políticas ótimas de POMDPs

Como já foi escrito, intenção é o estado que o agente se comprometeu a alcançar. O termo *i-plan* denota uma sequência de ações construídas para alcançar um determinado estado, ou seja, para alcançar uma determinada intenção. Para resolver essa questão, *i-plans* são relacionados com políticas, tendo como objetivo obter *i-plans* através da solução de um POMDP. Alguns exemplos podem ser vistos em (SIMARI; PARSONS, 2006).

Nesta seção adota-se a notação utilizada por (SIMARI; PARSONS, 2006) pois esta simplifica a descrição BDI e POMDP para que seja possível estabelecer relação entre seus elementos.

Um *i-plan*, denotado como ψ , possui indexação $\psi^{i,s}$, onde i é a intenção do agente e s seu estado atual. *I-plans* são sequências de ações e ψ_i denota a i -ésima ação em ψ , enquanto s_i^ψ denota o i -ésimo estado que o agente planeja visitar enquanto executa ψ . Portanto, para um *i-plan* ψ de tamanho p , o agente começa no estado s_0^ψ e planeja visitar os estados $s_1^\psi, s_2^\psi, \dots, s_p^\psi$. Se o agente precisar fazer uma reconsideração, e uma nova intenção for adotada o agente também irá precisar de um novo *i-plan*.

A utilidade esperada de um *i-plan* pode ser obtida da mesma forma que uma política em um POMDP, estabelecendo-se um valor para cada ação em cada estado em que é executada. A diferença é que em um *i-plan* considera-se apenas uma sequência no espaço de estados e, na avaliação de uma política, considera-se as ações em todos os estados. A princípio, o agente BDI terá a mesma abordagem para atravessar o espaço de estados. Selecionará uma intenção, identificará um *i-plan* para alcançar sua intenção e executará seu *i-plan* até perceber que seu *i-plan* não irá alcançar sua intenção ou que sua intenção não pode ser alcançada ou não é a melhor intenção possível. Nesse momento, o agente irá gerar um novo *i-plan* ou escolher uma nova intenção e gerar um *i-plan* para alcançá-lo e o processo irá se repetir (PEREIRA, 2008).

O resultado obtido nos trabalhos de (SIMARI; PARSONS, 2006) e (PEREIRA, 2008) é o de que, dada uma política, que tem uma ação para cada estado, é possível derivar um ou mais *i-plans*, determinando uma trajetória através do espaço de estados. Portanto, pode-se dizer que uma política incorpora um conjunto de *i-plans*.

3.4.2 Passagem de Política para *I-Plans*

Assume-se que uma política π é a solução para um POMDP especificado, e que π é ótima (esta condição é importante para os resultados que se querem obter). Entretanto, de qualquer política é possível extrair valores de utilidade para os estados que irão induzir π , e estes poderão ser usados para estabelecer *i-plans*.

De uma forma geral, para se atribuir valor para um *i-plan* é necessário que este tenha, para cada ação adicionada ao plano, valores de custo não negativos, e que estes valores dependam das recompensas dos estados que o agente planeja visitar.

A definição formal para um *i-plan* ψ , segundo (SIMARI; PARSONS, 2006), é dada da forma a seguir:

Definição 3.4.1. *Uma sequência de ações $\psi_0, \psi_1, \dots, \psi_p$, é chamada *i-plan* se as ações ψ_i , com $0 \leq i \leq p$, forem selecionadas para serem executadas uma de cada vez, na ordem da sequência para alcançar uma dada intenção.*

Definição 3.4.2. *Dado um *i-plan* $\psi = \psi_0, \psi_1, \dots, \psi_p$, diz-se que p é o tamanho de ψ .*

Definição 3.4.3. *(Definição de Obediência) Um *i-plan* ψ de tamanho p obedece a uma política π se, e somente se, $\forall i, 1 \leq i \leq p : \psi_i = \pi(s_{i-1}^\psi)$, onde s_i^ψ é o estado para qual o agente está planejando chegar após executar a ação ψ_i , e s_0^ψ é seu estado inicial.*

Assim, um *i-plan* obedece a uma política se, e somente se, as ações prescritas pelo *i-plan* são as mesmas prescritas pela política através dos estados intermediários do *i-plan*.

Definição 3.4.4. *(Definição de Conformidade) Uma política π está de acordo com um *i-plan* ψ de tamanho p se, e somente se, $\forall i, 1 \leq i \leq p : \psi_i = \pi(s_{i-1}^\psi)$ onde s_i^ψ é o estado que resulta da execução da ação ψ_i no estado s_{i-1}^ψ , e s_0^ψ é o estado no qual a primeira ação é executada.*

Ou seja, uma política está de acordo com um plano, se para cada ação descrita no plano a política recomenda a mesma ação.

Proposição 3.4.1. *Seja $\langle S, A, T, R, \Omega, O, P \rangle$ um agente POMDP e π uma política que é ótima sob um critério de máxima utilidade esperada. Seja $\langle S, A, T, B, D, I, Del, M \rangle$ um agente BDI, onde M e Del são ótimos sob um critério de máxima utilidade esperada. Se o ambiente for parcialmente observável, com S' sendo a contraparte parcialmente observável de S , e também não determinístico, isto é, $|T(s; a)| \geq 1$, então $\forall i \in I, \forall s' \in S'$, é válido que $\psi^{i, s'}$ obedece a π .*

Esta é uma formalização da relação entre políticas e *i-plans*. Esta correspondência é válida sob restritivas suposições, em particular se os requisitos (política, *M* e *Del*) forem ótimos, mas garante que os *i-plans* gerados refletem uma política ótima. Se necessário, pode-se relaxar a necessidade de um *i-plan* corresponder a uma política ótima, desta forma o *i-plan* é criado com menos restrições.

Fica realizada, desta forma, uma fundamentação teórica abrangente e detalhada das ferramentas utilizadas para a modelagem e simulação dos agentes inteligentes deste trabalho. Todas essas ferramentas só poderão ser utilizadas se for possível montar um planejamento adequado para a realização das tarefas que os agentes precisarão desempenhar. Tal estratégia¹¹ precisará ser reformulada a cada detecção dos sensores dos agentes. Assim, no capítulo seguinte serão definidas algumas teorias de planejamento e destas será destacada a estratégia que abrangerá o híbrido de agentes BDI e POMDPs, ou seja, os *i-plans*.

3.5 PLANEJAMENTO

Alguns autores como Peter Norvig¹² e Sebastian Thrun colocam o planejamento como o núcleo da Inteligência Artificial.

Planejamento consiste em apresentar uma sequência de ações que alcançarão um objetivo. Para o caso de ambientes determinísticos e totalmente observáveis, técnicas de planejamento clássico, como algoritmos de busca, são suficientes. Entretanto, em ambientes estocásticos, não determinísticos ou em ambos é preciso pensar em uma forma de relaxamento para tais algoritmos. Esse relaxamento, ou seja, esse tipo de planejamento é chamado de planejamento não-clássico.

Como já foi citado, o ambiente deste trabalho é estocástico e mais especificamente, pode-se dizer que o ambiente possui um indeterminismo ilimitado.

Em ambientes com essa característica um agente deve usar suas percepções para descobrir o que está acontecendo enquanto o plano está sendo executado e, possivelmente, modificar ou substituir o plano caso ocorra algo inesperado (NORVIG; RUSSELL, 2004). Ambientes não-determinísticos obrigam os agentes a lidar com informações incompletas e incorretas. Incompletas pela própria característica do ambiente e incorretas pois o ambiente não corresponde necessariamente ao “modelo” de ambiente. Por exemplo: “posso *acreditar* que será servido chá às 15 horas, mas hoje

¹¹ Planejamento ou Planning.

¹²Peter Norvig é diretor de pesquisa da Google Inc. Ele também é membro da Associação Americana de Inteligência Artificial e da Association for Computing Machinery. Norvig é co-autor do livro Inteligência Artificial: uma abordagem moderna. Antes de entrar no Google, ele era o chefe da Divisão de Ciências da Computação na NASA Ames Research Center.

tomei suco de laranja nesse mesmo horário”.

O conhecimento correto e completo é dependente da quantidade de indeterminações existentes no ambiente. Se o indeterminismo é limitado, as ações poderão ter efeitos imprevisíveis, mas os efeitos possíveis podem ser listados na classificação das descrições de ações, ou seja, o espaço amostral é conhecido e enumerável. Quando o ambiente possui indeterminismo ilimitado, o conjunto de precondições ou efeitos possíveis é desconhecido ou grande demais para ser enumerado completamente (NORVIG; RUSSELL, 2004). Neste caso, alguns métodos de planejamento podem ser adotados para suprir esta complexidade.

Alguns dos métodos de planejamento para lidar com o indeterminismo são (NORVIG; RUSSELL, 2004):

- Planejamento sem sensores (*sensorless planning*): Também chamado planejamento com conformação. Esse método constrói planos sequenciais que devem ser executados sem percepção. O algoritmo de planejamento sem sensores deve assegurar que o plano atingirá o objetivo em todas as circunstâncias possíveis, independente do verdadeiro estado inicial e dos reais resultados das ações. O planejamento sem sensores se baseia na coerção à ideia de que o mundo pode ser forçado a entrar em um determinado estado, mesmo quando o planejador só tem informações parciais a respeito do estado atual. A coerção nem sempre é possível, portanto o planejamento sem sensores frequentemente é inaplicável.
- Planejamento condicional: Essa abordagem lida com o indeterminismo limitado construindo um plano condicional com diferentes ramificações para as diferentes contingências que poderiam surgir. Da mesma maneira que no planejamento clássico, o agente planeja primeiro e depois executa o plano que foi produzido. O agente descobre qual parte do plano deve executar incluindo ações de detecção no plano para testar a presença das condições apropriadas. Por exemplo, no domínio de transporte aéreo, poderia ter planos como “verificar se o aeroporto de São Paulo está em operação”. Nesse caso, voar para lá; caso contrário, voar para o Rio de Janeiro;
- Monitoramento e replanejamento de execução. Na abordagem de replanejamento de execução, o agente pode usar técnicas de planejamento clássicas (sem sensores ou condicional) para construir um plano. Acoplado a essa abordagem utiliza-se o monitoramento de execução para julgar se o plano tem uma previsão referente à situação real atual ou precisa ser revisto. O replanejamento ocorre quando algo não funciona como esperado, assim o agente pode manipular o indeterminismo ilimitado.

- Planejamento contínuo. Esse é projetado para não finalizar o planejamento ao longo da simulação. Assim, enquanto os outros planejadores vistos até o momento são projetados para alcançar um objetivo e depois parar, um planejador contínuo é projetado para persistir ao longo de toda a “vida”. Ele pode manipular circunstâncias inesperadas no ambiente, ainda que essas ocorram enquanto o agente está no meio da construção de um plano. Ele ainda pode lidar com a desistência de objetivos e a criação de objetivos adicionais.

Esse dois últimos itens serão amplamente utilizados e analisados neste trabalho.

Um agente de monitoramento de execução é capaz de monitorar a execução de suas ações e replanejar conforme necessário. Os agentes deste tipo em geral implementam um dos seguintes tipos de monitoramento: de ação (considerado uma forma mais simples) ou de plano (uma forma mais complexa). No primeiro caso, o agente, em cada passo, verifica o ambiente a fim de avaliar se a próxima ação a ser executada irá funcionar. No segundo, mais complexo, uma verificação semelhante avalia todo o restante do plano (PEREIRA; SAITO; PEDRUZZI, 2012). Um agente de replanejamento sabe o que fazer quando ocorre algo inesperado, pois tem a capacidade de chamar novamente um planejador para apresentar um novo plano que irá atingir o objetivo. Esta checagem tem ainda a vantagem de detectar sucessos acidentais.

No caso de universos parcialmente observáveis o fator complicante quando se utiliza um monitoramento e replanejamento de execução, é que “checar as precondições” pode envolver ações de sensoriamento, que afetam o próprio planejamento. O agente deve focar-se, portanto, naquelas precondições que são mais importantes, têm chance de falhar e não são demasiadamente custosas para perceber.

Um agente de planejamento contínuo, ao contrário dos demais anteriormente apresentados, não é um simples resolvedor de problemas. É um agente capaz de persistir indefinidamente no ambiente podendo receber novos objetivos e reformulá-los durante o planejamento (NORVIG; RUSSELL, 2004). O planejamento contínuo é construído incrementalmente. A cada passo o agente checa suas percepções, resolve falhas no seu plano e pode retornar uma ação que já esteja pronta para ser executada.

Ao perceber mudanças em suas percepções, o agente inicia um processo de adaptação do plano, isto é, um processo em que determinados tipos de falhas no plano são identificados e corrigidos. Os tipos de correção de falhas são apresentados a seguir:

- a) remoção de casualidades que não são mais garantidas;
- b) extensão de uma probabilidade causal, pois uma condição pode ser promovida por uma ação anterior sem causar conflitos;

- c) remoção de ações que tornaram-se redundantes;
- d) remoção de uma ação para ser executada;
- e) inclusão de probabilidades para suprir uma condição que esteja aberta, podendo envolver a criação de uma nova ação; inclusão de novos objetivos e
- f) remoção de objetivos que foram alcançados.

Este agente é capaz de lidar com diversas dificuldades do agente de replanejamento tais como: atuar em tempo-real, detectar sucessos acidentais, formular seus próprios objetivos e lidar com eventos inesperados que afetam planos futuros. Desta forma o planejamento contínuo destaca-se para o uso neste trabalho por possuir características que permitem modelar e simular o comportamento aproximado de raciocínio de uma pessoa (PEREIRA; SAITO; PEDRUZZI, 2012).

3.6 VARIÁVEIS PSICOCOMPORTAMENTAIS

O comportamento humano real é afetado por aspectos psicológicos, biológicos, sociológicos, antropológicos, econômicos e políticos. Através do comportamento, a pessoa dá respostas a situações, criadas por estímulos internos ou externos, procurando satisfazer suas necessidades. A tomada de decisão e a execução da alternativa selecionada manifestam o comportamento do indivíduo. O agente inteligente precisa representar tais características de forma aproximada para que se possa dizer que se tem um bom modelo (LARRAÑAGA, 2008).

Quando os agentes escolhem o percurso que farão para chegar a seus objetivos, selecionam um conjunto de alternativas de um conjunto maior de possibilidades disponíveis, procurando satisfazer suas necessidades de deslocamento. A seleção da alternativa é baseada em um conjunto de crenças, preferências, aversões, predisposições internas, conhecimentos e julgamentos, baseados em um ser humano real, que geram um sistema de valoração e determinam o melhor percurso a ser seguido. A compreensão dessas preferências, e a investigação das razões implícitas nas escolhas possibilitam um planejamento do trajeto de forma mais adequada.

O primeiro trabalho que se refere ao estudo de comportamento de multidões foi publicado por Le Bon e intitulado *A Study of the Popular Mind* (2012). Com essa obra introduziu-se na literatura de comportamento de pedestres a ideia de consciência coletiva.

No seu sentido comum a palavra “multidão” significa uma reunião de indivíduos de qualquer nacionalidade, gênero, profissão, independente dos motivos que os tenha

reunido. Do ponto de vista psicológico, a expressão “multidão” assume um significado bastante diferente. Segundo Le Bon, sob certas circunstâncias, e só nessas circunstâncias, uma aglomeração de pessoas apresenta características muito diferentes daquelas dos indivíduos que a compõem. Os sentimentos e ideias tendem a se generalizar fazendo com que o grupo siga em uma mesma direção, e a personalidade consciente individual desaparece. A mente coletiva é transitória, mas apresenta características muito bem definidas. Ainda de acordo com Le Bon, uma multidão onde tais características podem ser observadas é considerada uma multidão organizada, ou ainda, uma multidão psicológica. Assim a multidão é caracterizada como um único bloco (ou agente) e fica sujeita à lei de unidade mental das multidões.

Quando a referência é o pânico, um dos precursores é Quarantelli (1957), fundador do Centro de Pesquisas de Desastres da Universidade de Delaware. Apesar de ter publicado seus trabalhos mais significativos nos anos 50, suas ideias são semelhantes aos conceitos atuais empregados em situações de pânico utilizados em modelagem. O motivo para Quarantelli ter seu conceito de pânico tão atual se dá por ter baseado seus trabalhos em estudos de sociólogos referentes ao comportamento humano em situações de desastres naturais e tecnológicos. De acordo com os sociólogos pesquisados por Quarantelli, o pânico é entendido como uma disfunção comportamental de fuga da realidade, gerada por motivo fortuito, mas envolvendo perigo eminente. Também afirmam que mesmo nesse estado imocional alterado, existe estruturação do raciocínio, sendo possível definir objetivos e ações para alcançar metas.

Em 1965 uma grande contribuição para o estudo de fugas em situações de pânico foi feita por Brown (1965). Seu livro intitulado “*Social Psychology*” traz explicações sobre níveis de aceitação de risco em tomadas de decisão em grupo. Brown defende que em uma vasta gama de decisões, o risco moderado normalmente aceitável individualmente torna-se expressivo e saliente numa discussão em grupo. Ou seja, quando o grupo em fuga atinge certo número de pessoas, a tomada de decisões passa ser mais complexa e o processo de aceitação do risco passa a ser bem mais lento e exigente.

Turner e Killian (1972) defendem a teoria de normas emergentes. A teoria propõe que as multidões normalmente desenvolvem padrões únicos de comportamento, e que estas normas atípicas exercem uma poderosa influência no comportamento coletivo. O normador pode ser um indivíduo (líder) ou regras pré-determinadas. Anderson descreve que mesmo em ambientes emergentes sem um líder específico, a massa se beneficia quando as orientações sobre a conduta que deve ser tomada em casos de situações de pânico já esteja definida. Assim, mensagens de voz, placas, etc facilitam a saída dos indivíduos em um ambiente caótico.

Desta forma, pode-se classificar as teorias explicativas do comportamento coletivo

em três tipos: teorias do contágio, de que é exemplo a obra de Gustave Le Bon, baseadas na rápida comunicação e na aceitação de uma liderança; teorias da convergência, baseadas na ideia de uma partilha de predisposições; e as teorias das normas emergentes, que encaram o comportamento coletivo como um comportamento que emerge em situações especiais mas que é ainda assim regulado por normas sociais.

Algumas variáveis psicocomportamentais são observadas com mais frequência nos casos de:

- Caminhada normal

1. Pedestres sentem aversão em tomar desvios ou andar em sentido contrário ao objetivo, mesmo que este esteja congestionado. No entanto, há também algumas evidências de que os pedestres normalmente escolhem o caminho mais rápido para seu próximo destino, mas não o mais curto (GANEM, 1998). Em geral, os pedestres levam em conta desvios, bem como o conforto de andar, minimizando assim o esforço para chegar ao seu destino (HELBING; KELTSCH; MOLNÁR, 1997).
2. Os pedestres preferem andar com uma velocidade individual desejada, que corresponde à velocidade mais confortável (que consuma menos energia) (WEIDMANN, 1993), desde que não haja a necessidade de caminhar mais rápido a fim de alcançar o objetivo a tempo. As velocidades desejadas dentro de multidões de pedestres são distribuições Gaussianas com um valor médio de cerca de $1,34 \text{ m/s}$, e um desvio padrão de cerca de $0,26 \text{ m/s}$ (ENDERSON, 1971). No entanto, a velocidade média depende da situação (ULLRICH, 1967; PREDTETSCHENSKI; MILINSKI, 1971), gênero e idade, tempo do dia, finalidade da viagem, etc (WEIDMANN; BUCHMUELLER, 2006).
3. Os pedestres mantêm uma certa distância em relação a outros pedestres e fronteiras (de ruas, paredes e obstáculos; (BRILON; GOSSMANN; BLANKE, 1994; BOARD, 1985). Esta distância diminui se a demanda de velocidade aumenta, e a densidade nessas fronteiras cresce proporcionalmente a esse aumento de velocidade (pressa de cada indivíduo).

- Pânico

1. Em situações de evacuação com pânico os agentes tendem a ficar mais nervosos, ou seja, tendem a desenvolver ações cegas (STEINBERG, 2005).
2. As pessoas tendem a caminhar com velocidades consideravelmente mais altas (PREDTETSCHENSKI; MILINSKI, 1971).

3. Os indivíduos começam a empurrar, e as interações entre as pessoas se tornam de natureza física (HELBING; MOLNÁR, 1995).
4. A movimentação, em particular a passagem em gargalos, frequentemente tornam-se descoordenadas (MINTZ, 1951).
5. As interações físicas em multidões congestionadas podem causar pressões perigosas de até 4.500 Newtons por metro (ELLIOTT; SMITH, 1993; TURNER; KILLIAN, 1972) que podem fazer com que barreiras de aço sejam entortadas ou até derrubar paredes de tijolos.
6. A fuga é retardada por pessoas caídas ou feridas que se transformam em obstáculos (HELBING; MOLNÁR, 1995).
7. As pessoas tendem a mostrar comportamento de rebanho, ou seja, fazer o que outras pessoas fazem (QUARANTELLI, 1957; KEATING, 1982).
8. As saídas alternativas são muitas vezes ignoradas ou não utilizadas de forma eficiente em situações de fuga (KEATING, 1982; ELLIOTT; SMITH, 1993).
9. o movimento dos pedestres usuários de um sistema não são necessariamente em linha reta, mas aleatórios em uma faixa do terreno (BENTHORN; FRANTZICH, 1998).

A pesquisadora Angela Behrendt¹³, vem investigando as áreas cerebrais que determinam características de pensamentos. Behrendt divide essas características em: pensamento único, especializado, situacional, interligado, iterativo, dominante, maleável e integral; e determina dentro dessas características o que denomina de “Quatro Identidades” (BEHRENDT, 2011).

As Quatro identidades são divididas em:

1. O ser Racional - Este é capaz de analisar, quantificar. É lógico, crítico, realista. Gosta de números, sabe sobre dinheiro, sabe como as coisas funcionam.
2. O ser Experimental - Este infere, imagina, especula, assume riscos, é impetuoso, quebra as regras, gosta da surpresa, é curioso, joga.
3. O ser Custódia - Este toma medidas preventivas. Estabelece procedimentos. Faz as coisas. É confiável, oportuno. Planeja.
4. O ser Emotivo - Este é sensível aos outros. Gosta de ensinar. Gosta de tocar. É solidário, expressivo, emotivo. Fala muito e sente.

¹³Angela Behrendt é professora na Universidade de Málaga - Espanha.

Os agentes serão divididos em grupos, de acordo com a pesquisa de Behrendt, considerando, que tais características podem coexistir em um mesmo agente, sendo que tem-se como hipótese que, uma das identidades é dominante. Desta forma, pode-se classificar as possíveis reações que um agente, por exemplo, com identidade racional, teria.

Portanto, é possível citar algumas reações prováveis de cada uma das identidades, respectivamente aos itens anteriores:

1. Analisa os fatos. Lida de forma lógica e racional.
2. “Visualiza” os fatos. Lida de forma intuitiva e holisticamente.
3. Organiza os fatos. Lida de forma realista e cronologicamente.
4. “Sente” os fatos. Lida expressivamente e interpessoalmente.

Para a modelagem dos agentes deste trabalho, usa-se como hipótese que as variáveis psicocomportamentais estão descritas em função das quatro identidades comportamentais, definindo dessa forma: agentes Racionais, agentes Custódias, agentes Experimentais e agentes Emotivos. Cada um desses grupos de agentes serão alimentados pelas demais características referenciadas quando se trata de situações de estresse. Essa convenção simplificadora para as variáveis psicocomportamentais será dada visando uma caracterização de forma similar à descrição de cada personalidade definidas por Behrendt.

3.7 CURVAS DE BÉZIER

As curvas de Bézier serão utilizadas para modelar a caminhada dos agentes BDI. A escolha por esse padrão de curva se dá pela semelhança observada em suas interpolações e o que acontece quando pedestres se locomovem.

O conceito matemático da Curva de Bézier foi originalmente desenvolvido pelo francês Pierre Bézier para a indústria automobilística, nos anos 60 (BÉZIER,). A proposta de Bézier foi a construção de uma ferramenta de desenho que usava o conceito matemático de aproximações polinomiais, com ajustes muito suaves, para que fosse possível trabalhar o design dos carros modernos sem abrir mão da agilidade computacional para a solução de tais aproximações (ALVES, 2013).

Com os conceitos que serão apresentados neste capítulo é possível verificar que características como a velocidade média de um pedestre, são preservadas quando esse mesmo pedestre caminha sobre uma curva de Bézier. A velocidade instantânea

dos pedestres fica representada e dependente do raio de curvatura da Bézier, sendo que para raios maiores, a velocidade é maior e para raios menores a velocidade é menor. Além disso, esse tipo de curva possui propriedades inerentes de diferenciabilidade que lhe garantem características como: continuidade, suavidade, etc, e, desta forma, a representação da caminhada de pedestres se dá de forma adequada e similar ao que ocorre no real.

Originalmente Bézier baseou-se em princípios geométricos¹⁴, porém mais tarde, Forrest (1990), Gordon e Riesenfeld (1974) mostraram que o resultado é equivalente à base de Bernstein, ou função de aproximação polinomial.

A curva de Bézier emprega no mínimo 2 pontos (ALVES, 2013), chamados de pontos de controle, para sua definição, podendo chegar a n pontos. Por exemplo, sua forma cúbica é definida por quatro pontos sendo: 2 pontos âncoras ou pontos extremos e dois pontos intermediários ou pontos de controle, que não passam pela curva, mas definem sua forma. A linha que une um ponto de controle anterior, (P_0) , a um outro ponto de controle na sua sequência, (P_1) , é a reta tangente a curva no ponto de controle anterior, (P_0) , e, por isso, é ela que determina a declividade da curva neste ponto, como pode ser observado na Fig. (2).




FIGURA 2: Construção da curva Bézier cúbica.

Uma curva de Bézier de grau n é determinada por um conjunto de pontos de controle $P_i, i = 0, \dots, n$, tais que estes formam um polígono característico denominado de polígono de Bézier ou polígono de controle, o qual define por si só a tendência da forma de uma curva de Bézier.

A notação para a teoria das curvas Bézier será dada da forma paramétrica, por ser a notação que melhor se apresenta quando há necessidade de uma posterior resolução computacional.

A forma paramétrica permite uma descrição uniforme dos diferentes tipos de curvas através da adoção de um intervalo fixo de variação da coordenada paramétrica. Geralmente utiliza-se o intervalo $[0, 1]$.

¹⁴Algoritmo de Casteljau

Uma curva de Bézier é definida como (DIAS, 2000):

$$B(t) = \sum_{i=0}^n P_i J_{n,i}(t) \quad 0 \leq t \leq 1 \quad (14)$$

onde P_i são os pontos de controle e $J_{n,i}(t)$ são polinômios de Bernstein, também chamados de funções de mistura e são dados por:

$$J_{n,i}(t) = C_n^i t^i (1-t)^{n-i} \quad (15)$$

com $C_n^i = \frac{n!}{i!(n-i)!}$. Desta forma, a equação de Bézier para um segmento de curva paramétrica é a combinação linear entre polinômios de Bernstein e os vértices do polígono de Bézier. O grau da função de mistura é sempre uma unidade a menos que o número de pontos do polígono de definição.

A equação para a curva de Bézier pode ser expressa na forma matricial. Assim, para $n = 3$ (a maioria dos projetos de modelamento utilizam uma curva de grau 3 para definir a estrutura desejada) tem-se:

$$B(t) = \begin{bmatrix} (1-t)^3 & 3t(1-t)^2 & 3t^2(1-t) & t^3 \end{bmatrix} \begin{bmatrix} P_0 \\ P_1 \\ P_2 \\ P_3 \end{bmatrix} \quad (16)$$

Desenvolvendo e agrupando os termos do parâmetro pode-se reescrever como:

$$B(t) = \begin{bmatrix} t^3 & t^2 & t & 1 \end{bmatrix} \begin{bmatrix} -1 & 3 & -3 & 1 \\ 3 & -6 & 3 & 0 \\ -3 & 3 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} P_0 \\ P_1 \\ P_2 \\ P_3 \end{bmatrix} \quad (17)$$

Observa-se que as funções de Bernstein são o elemento chave para definir o comportamento das curvas de Bézier.

3.7.1 Propriedades das Curvas de Bézier

Duas propriedades das curvas de Bézier são fundamentais (DIAS, 2000):

1. Conhecer o comportamento da tangente à curva;
2. Calcular a curvatura sobre ela.

Observe que a curva paramétrica cúbica de Bézier interpola os pontos extremos do conjunto de vértices ao ser feito $t = 0$ e $t = 1$ na Eq. (14).

$$\begin{aligned} B(0) &= P_0 \\ B(1) &= P_3 \end{aligned} \quad (18)$$

Ao diferenciar a Eq. (17) e rearranjando os termos, obtém-se:

$$B'(t) = 3 \begin{bmatrix} (1-t)^2 & 2t(1-t) & t^2 \end{bmatrix} \begin{bmatrix} (P_1 - P_0) \\ (P_2 - P_1) \\ (P_3 - P_2) \end{bmatrix} \quad (19)$$

Ou seja, a tangente à curva é uma forma parabólica, que é influenciada por vetores formados pelos vértices do polígono de controle. Quando $t = 0$ e $t = 1$, obtém-se da Eq. (19) que:

$$\begin{aligned} B'(0) &= 3(P_1 - P_0) \\ B'(1) &= 3(P_3 - P_2) \end{aligned} \quad (20)$$

Isso mostra que o vetor formado pelos pontos extremos e os pontos intermediários, P_1 e P_2 , respectivamente, (ampliados 3 vezes) definem vetores tangentes nos pontos extremos. Desta forma, a curva de Bézier fornece o controle direto sobre os vetores tangentes ao pontos nos finais da curva, através dos pontos vizinhos aos pontos extremos.

Diferenciando duas vezes a Eq. (17) e rearranjando os seus termos obtém-se a segunda derivada da curva em função dos pontos de controle, dado por

$$B''(t) = 6 \begin{bmatrix} (1-t) & t \end{bmatrix} \begin{bmatrix} (P_2 - 2P_1 + P_0) \\ (P_1 - 2P_2 + P_3) \end{bmatrix} \quad (21)$$

o que mostra que a segunda derivada nos pontos extremos é determinada pelos vértices vizinhos consecutivos. Isto fornece o controle da continuidade de curvatura da curva no ponto de junção, ao precisar interpolar um conjunto de pontos formado por segmentos de curvas de Bézier.

3.7.2 Propriedades das funções de Bernstein

As funções de ajustes ou de mistura das curvas de Bézier dadas em termos das funções de Bernstein tem um papel preponderante na forma e no controle dessas curvas (DIAS, 2000). Assim, serão enumeradas algumas de suas propriedades e, em alguns casos, exemplificadas.

1. Positividade

$$0 \leq J_{n,i}(t) \leq 1, \quad t \in [0, 1] \quad (22)$$

2. Partição da Unidade

$$\sum_{i=0}^n J_{n,i}(t) = 1, \quad t \in [0, 1] \quad (23)$$

3. Recursão

$$J_{n,i}(t) = (1-t)J_{n-1,i}(t) + tJ_{n-1,i-1}(t), \quad i = 0, \dots, n \quad (24)$$

4. Simetria

$$J_{n,n-i}(t) = J_{n,i}(1-t) \quad (25)$$

5. Função Diferenciável

$$J'_{n,i}(t) = nJ_{n-1,i-1}(t) - J_{n-1,i}(t), \quad i = 0, \dots, n \quad (26)$$

6. Propriedades Geométricas nos Pontos Finais

De acordo com a propriedade de positividade das funções de Bernstein, obtém-se que:

$$\begin{aligned} B(0) &= P_0 \\ B(1) &= P_n \end{aligned} \quad (27)$$

Usando a Eq. (26) pode-se obter:

$$\begin{aligned} B'(t) &= \sum_{i=0}^n J'_{n,i}(t)P_i = n \sum_{i=0}^n J_{n-1,i-1}(t) - J_{n-1,i}(t)P_i \\ &= n \sum_{i=0}^n J_{n-1,i-1}(t)(P_i - P_{i-1}) \end{aligned} \quad (28)$$

Desta forma é possível escrever que o valor da tangente é:

$$\begin{aligned} B'(0) &= n(P_1 - P_0) \\ B'(1) &= n(P_n - P_{n-1}) \end{aligned} \quad (29)$$

Continuando essa idéia tem-se:

$$\begin{aligned} B''(0) &= n(n-1)[(P_2 - P_1) - (P_1 - P_0)] \\ B''(1) &= n(n-1)[(P_n - P_{n-1}) - (P_{n-1} - P_{n-2})] \end{aligned} \quad (30)$$

Desta forma, a k -ésima derivada nos pontos extremos é dada por:

$$\begin{aligned} B^k(0) &= \frac{n!}{(n-k)!} \sum_{i=0}^k (-1)^{k-i} C_k^i P_i \\ B^k(1) &= \frac{n!}{(n-k)!} \sum_{i=0}^k (-1)^i C_k^i P_{n-i} \end{aligned} \quad (31)$$

7. Propriedade do Contorno Convexo

A condição de positividade garante que a curva de Bézier fique completamente dentro do contorno convexo formado pelos vértices do polígono de controle. Assim, pode-se afirmar que a curva de Bézier é a soma da média dos pesos dos vértices, ponderado pelas funções de Bernstein e por isso elas são também chamadas de funções peso. Assim, as curvas de Bézier caem sempre dentro do contorno convexo dos $n + 1$ vértices de controle. Uma forma de visualizar, no plano o contorno convexo formado pelos pontos de controle é dado pela passagem de um elástico através deles formando um polígono limite de todos os pontos.

8. Propriedade de Invariância Geométrica

A forma da curva de Bézier é determinada somente por seus vértices e não há qualquer relacionamento com o sistema de coordenadas usado, como é comum para curvas paramétricas em geral. A propriedade da partição da unidade garante que a relação entre a curva e o polígono de controle seja invariante a transformações de sistema de coordenadas. Isso significa que as transformações geométricas de translação, rotação e escalamento, mais o cisalhamento, inferidas à curva de Bézier precisam ser aplicadas somente ao polígono de controle, sem a necessidade de transformar cada ponto da curva em si.

9. Propriedade de Recursão Linear

A propriedade de recursão pode ser usada para construir uma curva $J_{n,i}$ a partir do conhecimento dos polinômios de Bernstein de mais baixa ordem.

3.7.3 Algoritmo de De Casteljau para solução da curva de Bézier

O Algoritmo de De Casteljau é um método recursivo para calcular polinômios na forma de Bernstein ou da Curva de Bézier. Assim, as funções de recursão de Bernstein conduzem a gerar o algoritmo de De Casteljau para o cálculo de $B(t)$ para um determinado valor de t (DIAS, 2000).

$$B_{i,l}(t) = (1-t)B_{i,l-1}(t) + tB_{i+1,l-1}(t), \quad (32)$$

$$t \in [0, 1], \quad i = 0, \dots, n-1, \quad l = 1, \dots, n$$

onde $B_{i,0} = P_i$, $i = 0, \dots, n$. O índice l determina a ordem da recursão e o índice i a ordem dos pontos auxiliares.




FIGURA 3: Recursão de De Casteljau.

Observa-se que a recursão dos coeficientes binomiais assegura a recursão das funções de Bernstein e por outro lado a recursão das funções de Bernstein garante a recursão do algoritmo de De Casteljau.

Então, seja uma curva de Bézier definida por um conjunto de pontos de controle $P_i, i = 0, \dots, 3$, e se quer calcular um ponto sobre a curva em $t = \frac{1}{3}$ ou seja, $B(\frac{1}{3})$. Neste caso, para cada valor de $l = 1, \dots, 3$, deve-se fazer:

1. Da Eq. (32) pode-se obter o conjunto de pontos da primeira recursão $B_{i,1}(\frac{1}{3})$, onde $l = 1$. Assim, tem-se:

$$\begin{aligned} B_{i,1}\left(\frac{1}{3}\right) &= \left(1 - \frac{1}{3}\right)B_{i,0} + \frac{1}{3}B_{i+1,0} \\ &= \left(1 - \frac{1}{3}\right)P_i + \frac{1}{3}P_{i+1}, \quad i = 0, \dots, 2. \end{aligned} \quad (33)$$

2. para $B_{i,2}(\frac{1}{3})$, ou seja, $l = 2$, tem-se:

$$B_{i,2}\left(\frac{1}{3}\right) = \left(1 - \frac{1}{3}\right)B_{i,1} + \frac{1}{3}B_{i+1,1}, \quad i = 0, \dots, 1. \quad (34)$$

3. para $B_{i,3}(\frac{1}{3})$, ou seja, $l = 3$, tem-se:

$$B_{i,3}\left(\frac{1}{3}\right) = \left(1 - \frac{1}{3}\right)B_{i,2} + \frac{1}{3}B_{i+1,2}, \quad i = 0. \quad (35)$$

O resultado do algoritmo pode ser guardado numa matriz da forma:

$$\begin{bmatrix} B_{0,0} \\ B_{1,0} & B_{0,1} \\ B_{2,0} & B_{1,1} & B_{0,2} \\ B_{3,0} & B_{2,1} & B_{1,2} & B_{0,3} \end{bmatrix}$$

onde a coluna 1 contém os pontos de controle inicial, e as colunas 2 a 4 representam os elementos calculados em cada passo da recursão, gerando um algoritmo simples que se baseia em subdivisão de retas.

Um exemplo geométrico com alguns valores para t entre 0 e 1 pode ser visto na Fig. (4):




FIGURA 4: Tem-se que $P_0 = B_{0,0}$, $P_1 = B_{1,0}$, $P_2 = B_{2,0}$ e $P_3 = B_{3,0}$. FONTE: Wikimedia.org. Autor: Phil Tregoning, 2007.

Para provar o que foi obtido no último passo do algoritmo, ou seja, que o ponto $B_{0,n}(t)$ é um ponto sobre $B(t)$ pode ser usado o método indutivo. Ou seja, pela recursão tem-se que:

$$B_{i,n}(0) = \sum_{i=0}^n J_{n,i}(t) P_i \quad (36)$$

Ao fazer $n = 1$, a Eq. (36) é válida pois a curva de Bézier é de primeiro grau (uma reta paramétrica) e a curva e polígono de controle são coincidentes. Assume-se um polígono de controle com vértices P_0, P_1, \dots, P_n . Usando a fórmula recursiva (32) obtem-se:

$$B_{i,n-1}(t) = \sum_{i=0}^{n-1} J_{n-1,i}(t) P_i = \sum_{i=0}^n J_{n-1,i}(t) P_i,$$

pois $J_{n-1,n}(t) = 0$.

Ao assumir um outro polígono de controle, com vértices P_1, P_2, \dots, P_n e usando fórmula recursiva (32) tem-se:

$$B_{i,n-1}(t) = \sum_{i=0}^{n-1} J_{n-1,i}(t) P_{i+1} = \sum_{i=0}^n J_{n-1,i-1}(t) P_i,$$

pois $J_{n-1,n}(t) = 0$.

Ainda, de acordo com a Eq. (36), pode-se escrever que:

$$\begin{aligned}
 B_{0,n}(t) &= (1-t)B_{0,n-1}(t) + tB_{1,n-1}(t) \\
 &= (1-t) \sum_{i=0}^n J_{n-1,i}(t)P_i + t \sum_{i=0}^n J_{n-1,i-1}(t)P_i \\
 &= \sum_{i=0}^n \{ (1-t)J_{n-1,i}(t)P_i + tJ_{n-1,i-1}(t)P_i \}
 \end{aligned} \tag{37}$$

e pela equação de recursão dos polinômios de Bernstein pode-se escrever

$$B_{0,n}(t) = \sum_{i=0}^n J_{n,i}(t)P_i$$

que demonstra a Eq. (36).

Deve-se observar que o algoritmo de De Casteljau aplicado para cada parâmetro t da curva pode ser usado para gerar a própria curva paramétrica.

Esse método de fácil implementação computacional servirá para gerar as curvas de Bézier que serão, como dito anteriormente, o traçado descrito pelos agentes ao caminharem pelo ambiente.

3.8 INTERAÇÕES GEOMÉTRICAS

Algumas interações geométricas serão necessárias para que seja possível representar visualmente o ambiente e os agentes. Tais interações também serão utilizadas para justificar algumas mudanças de comportamento, como por exemplo, evitar obstáculos.

Desta forma, os agentes serão representados por cilindros, para que se tenha semelhança ao corpo de um pedestre, podendo definir altura e diâmetro de cada cilindro.




FIGURA 5: Comparação entre as dimensões de pedestres e cilindros.

As paredes e pisos serão representados por paralelepípedos.

Uma importante parte das interações geométricas está na representação dos sensores dos agentes. Definiu-se que cada agente possuirá um cone de visão (FREITAS, 2014; STEMMER *et al.*, 2005) e através dele identificará obstáculos, paredes, portas e outros agentes. O cone de visão será o sensor de cada agente e este será responsável por toda a informação e observação obtida. A representação geométrica do cone de visão, como o próprio nome sugere, é um cone, Fig. (6).




FIGURA 6: Representação do Cone de Visão girando pelo ambiente.

As interações entre essas formas geométricas serão, a seguir, definidas.

3.8.1 Detecção de um ponto dentro de um cone

O problema de detectar um ponto dentro de um cone pode ser resolvido de diversas formas. A maneira escolhida para este trabalho se dá por sua simplicidade de programação.

Seja um cone de revolução gerado pelo vetor \vec{u} que gira ao redor do eixo das abscissas conforme se observa na Fig. (7).





FIGURA 7: Cone de Revolução

Seja um ponto P no plano cartesiano que origina o vetor $OP = \vec{k}$, conforme Fig. (8).

FIGURA 8: Ponto P em xOy

Para garantir que P está dentro do cone gerado por \vec{u} é necessário verificar duas condições:

1. Comprimento de \vec{k} deve ser menor do que comprimento de \vec{h} ;
2. Ângulo formado entre \vec{u} e \vec{k} mais o ângulo formado entre \vec{k} e \vec{h} deve ser igual ao ângulo formado entre \vec{u} e \vec{h} .

Se tais condições forem satisfeitas, pode-se dizer que P pertence ao cone gerado por \vec{u} .

3.8.2 Ponto de Intersecção entre retas finitas

Da mesma forma que nas outras interações geométricas, há diversas formas de se calcular a intersecção entre duas retas finitas e encontrar seu ponto de cruzamento, se existir.

Também pela simplicidade de programação opta-se pela teoria a seguir.

Sejam três pontos em um plano cartesiano, A , B e C . A solução consiste em determinar primeiramente se esses três pontos podem ser listados em sentido anti-horário, conforme Fig. (9).




FIGURA 9: Plano cartesiano com pontos A , B e C .

Para que isso seja verificado é necessário calcular a inclinação do segmento de reta \bar{AB} e do segmento de reta \bar{AC} . Se a inclinação de \bar{AB} for menor do que a inclinação de \bar{AC} então os três pontos podem ser listados em sentido anti-horário.

Agora, sejam dois segmentos de reta \bar{AB} e \bar{CD} . Se os pontos (A, C, D) estiverem em um sentido (horário ou anti-horário) diferente do sentido dos pontos (B, C, D) e o mesmo puder ser constatado para os pontos (A, B, C) e (A, B, D) , ou seja, A , B e C está listado em um sentido oposto a A , B e D , então pode-se afirmar que os segmentos de reta \bar{AB} e \bar{CD} se interceptam.

Após conferir a intersecção, ainda é necessário calcular o ponto onde esses segmentos de reta se cruzam. Sejam ainda os pontos citados: $A(x_a, y_a)$, $B(x_b, y_b)$, $C(x_c, y_c)$ e $D(x_d, y_d)$. Para encontrar o ponto $P(x, y)$ de intersecção entre os segmentos \bar{AB} e \bar{CD} faz-se:

$$P(x, y) = \left(\frac{\frac{(x_a y_b - y_a x_b)(x_c - x_d) - (x_a - x_b)(x_c y_d - y_c x_d)}{(x_a - x_b)(y_c - y_d) - (y_a - y_b)(x_c - x_d)}, \frac{(x_a y_b - y_a x_b)(y_c - y_d) - (y_a - y_b)(x_c y_d - y_c x_d)}{(x_a - x_b)(y_c - y_d) - (y_a - y_b)(x_c - x_d)} \right) \quad (38)$$

Desta forma pode-se usar o ponto P de intersecção entre os segmentos de reta \bar{AB} e \bar{CD} .

3.8.3 Colisões entre formas geométricas dinâmicas

Se for possível dizer que as formas geométricas que compõem um plano cartesiano se movimentam dentro deste e podem colidir, precisamos de uma equação que descreva quando ocorre essa colisão. As formas geométricas que compõem nosso ambiente são basicamente: cilindros e paralelepípedos. Para determinar suas colisões é necessário conhecer seus pontos de gravidade ou centroides. Assim, conforme

se pode verificar na Fig. (10), cada sólido geométrico possui um centroide, C_1 e C_2 , e a distância desse centroide até as paredes do sólido, r_1 e r_2 .




FIGURA 10: Centroides

Desta forma, para a colisão entre agentes tem-se que:

- Se a distância entre os dois centroides, d , for maior do que $r_1 + r_2$, diz-se que os sólidos geométricos não colidem.
- Se $r_1 + r_2 = d$, ocorre colisão, conforme se observa em Fig. (11).




FIGURA 11: Colisão entre cilindros.

Já a colisão entre paredes e agentes é dada em função de dois vetores, \vec{u} e \vec{v} de acordo com a Fig. (12). Tais vetores têm origem no centroide do agente e apontam para os pontos de início e final da linha que passa pelo centroide da parede.




FIGURA 12: Colisão entre Paralelepípedos e Cilindros.

A colisão é dada quando o ângulo α entre esses dois vetores for maior do que

$$(180^\circ - tol),$$

onde *tol* é a tolerância de controle dada pelo ângulo que os vetores formam com a linha central da parede quando a face do formato geométrico representativo do agente está em contato com a face do paralelepípedo representativo da parede.

3.9 PYTHON

Python é uma linguagem de programação interpretada, bastante portátil, de código-fonte aberto e disponível para todos os sistemas operacionais. Uma linguagem interpretada é aquela que não precisa ser compilada, ou seja, traduzida para uma linguagem de máquina. A linguagem é apenas “lida” por um outro programa, chamado interpretador, que traduz para a máquina o que o programa deseja realizar. Apresenta semântica dinâmica, um moderno mecanismo de tratamento de erros e exceções. O Python possui uma forma eficiente de acesso e reutilização de código com o uso de módulos, coleta de lixo automática, recursos avançados de manipulação de textos, listas e outras estruturas de dados, como dicionários, por exemplo (PETTELE, 2011). Além disso, o Python possui uma sintaxe simples, quase como um pseudo-código.

Em Python as funções são tratadas como objetos (incluindo herança múltipla), característica de linguagens de programação funcional como Lisp¹⁵, muito utilizada em aplicações de inteligência artificial (DESCONHECIDO, 2012).

Os módulos, em Python, são coleções de funções. Possui módulos como o cgi (para programação de páginas dinâmicas), ftplib (para montagem de scripts para interação com servidores FTP), gzip (para leitura e escrita de arquivos comprimidos), math (para utilização de funções matemáticas), re (para busca de texto com expressões regulares, característica da linguagem Perl), string (para operações com strings), time (para obtenção de hora atual e conversão de formatos de data), xmlilib (para interpretação de arquivos em formato XML). Há também módulos para computação científica e AI como por exemplo: NumPy, Scipy, VPython, Pymc, descritos a seguir.

O NumPy é um conjunto de bibliotecas para Python que oferecem várias funcionalidades para manipulação de conjuntos de objetos chamados arrays. Estes, por sua vez, podem ter qualquer número de dimensões. A vantagem destas extensões é que é possível processar grandes conjuntos de forma tão rápida quanto os resultados das linguagens não interpretadas de mais baixo nível. Pode-se, por exemplo, trabalhar com manipulação de grandes conjuntos numéricos, que é o caso do processamento de imagens. Além disso, a biblioteca NumPy possui diversas funções e operações sofisticadas incluindo ferramentas para álgebra linear, transformadas de Fourier e fer-

¹⁵A linguagem Lisp foi projetada primariamente para o processamento de dados simbólicos. É uma linguagem formal matemática. (MCCARTHY, 1962)

ramentas para geração de números aleatórios.

O SciPy é um pacote da linguagem Python que implementa diversas técnicas úteis na computação científica. Utiliza como base o NumPy para lidar eficientemente com grandes quantidades de números, e implementa em linguagem C diversos algoritmos numéricos e simbólicos para o processamento matemático (PYSCIENTE, 2012). Entre as capacidades do SciPy, podem-se:

1. Algoritmos Genéticos
2. Estatísticas
3. Otimização
4. Integração numérica
5. Processamento de sinais e imagens
6. Solução de equações diferenciais
7. Funções especiais (Bessel, etc.)
8. Polinômios

O Vpython é a ferramenta responsável pela parte de visualização 3D deste trabalho. Ou seja, o módulo que será utilizado é chamado de “Visual”, que é justamente o módulo de gráficos 3D usado para a linguagem de programação Python. VPython é o nome da combinação da linguagem de programação Python, o módulo Visual, e o ambiente de desenvolvimento IDLE.

Por se tratar de uma programação simples e fácil de aprender é muito usada para a criação de modelos 3D interativos de sistemas físicos (SCHERER, 2014). O Vpython foi criado em 2000 por David Scherer, enquanto ele era um estudante de graduação na Universidade de Carnegie Mellon. Tal módulo permite criar e animar objetos 3D, além da possibilidade de navegar em uma cena 3D girando, aproximando e afastando, usando apenas o mouse.

É possível criar objetos em qualquer escala. Por exemplo criar uma esfera com um raio de $1E-15$ m para representar um núcleo, ou uma esfera com um raio de $1E6$ m para representar um planeta.

Uma curiosidade do Vpython é a de que nem todos os objetos são visíveis. Por exemplo, VPython permite criar quantidades vetoriais em 3D e executar operações vetoriais sobre elas. Essa ferramenta vetorial também foi muito utilizada neste trabalho.

O pyMC (FONNESBECK, 2014) é um módulo python que implementa modelos estatísticos bayesianos e algoritmos de filtragem, incluindo cadeias de Markov Monte Carlo. Sua flexibilidade e extensibilidade torna-o aplicável a um grande conjunto de problemas.

PyMC fornece funcionalidades para fazer análise Bayesiana da forma mais simples. Aqui está uma pequena lista de algumas de suas características:

- Serve para modelos estatísticos bayesianos com cadeia de Markov Monte Carlo e outros algoritmos.
- Inclui um grande conjunto de distribuições estatísticas bem documentados.
- Usa o Numpy para cálculos numéricos.
- Inclui um módulo para a modelagem de processos de Gaussianos.
- Loops de amostragens podem ser pausados e ajustados manualmente, ou salvos e reiniciados mais tarde.
- Cria sumários inclusive de tabelas e gráficos.
- Vários diagnósticos de convergência estão disponíveis.
- Incorpora facilmente métodos personalizados e distribuições de probabilidade incomuns.

Optou-se por desenvolver o filtro de partículas, necessário neste trabalho, com o pyMC, pois este permite que se façam construções estatísticas de forma eficiente e se adapta a qualquer modelo ou distribuição que seja necessária dentro de um ambiente Python. Dessa forma não foi necessário que se programasse o Filtro de Partículas.

4 MÉTODOS

A simulação da caminhada de pedestres será realizada usando todas as ferramentas teóricas apresentadas no Cap. (3) que serão neste capítulo adequadas à teoria de movimentação de pedestres em situações de estresse.

Assim, inicialmente precisa-se lembrar que os ambientes trabalhados serão parcialmente observáveis o que justifica o uso de POMDP. Além disso e pelo mesmo motivo será usado um filtro de partículas (PF). É nesse momento que o módulo pyMC, definido na Sec. (3.9) será exigido. O PF é quem alimenta o POMDP para gerar políticas quase ótimas, que também podem ser denominadas planos. Esses planos, juntamente com a carga de crenças, desejos e intenções referentes ao agente BDI, serão responsáveis por produzir os *i-plans*, que determinam a movimentação do agente no ambiente. Essa movimentação ou percurso será traçado através de curvas de Bézier.

O planejamento ou política de um agente pode sofrer alterações durante toda a caminhada. Tais alterações dependerão de obstáculos como portas, outros agentes ou custos muito elevados ou baixos que acarretarão na mudança da Bézier seguida pelos agentes.

Sabe-se que para traçar uma curva de Bézier necessita-se de pontos de controle. Esse pontos de controle, que serão chamados de pontos de controle padrão, estão inicialmente predeterminados no ambiente. Conhecidos os pontos inicial e final, os pontos de controle da curva de Bézier são selecionados de forma a simular um traçado para o agente que se assemelhe à caminhada de um pedestre. O *i-plan* determinará o conjunto de caminhos ótimos e conseqüentemente a porta ou local para onde o agente deve seguir.

4.1 GERAÇÃO DE *I-PLANS*

Como já foi visto, o princípio de um processo de PF se dá ao se fazer uma distribuição de partículas pelo ambiente, através de um conjunto de amostras aleatórias com pesos associados (partículas), baseando-se em toda a informação disponível, incluindo as medidas atuais recebidas (seguindo as etapas de predição e atualização) (AIUBE, 2005). Neste trabalho, as informações disponíveis são os custos predeterminados para o ambiente, que são dinâmicos e precisarão ser atualizados de acordo com as tomadas de decisão do agente.

O pyMC é um módulo da programação Python que resolve um algoritmo sequencial de Monte Carlo, ou seja, resolve um filtro de partículas. Após algumas iterações, o algoritmo faz com que essas partículas se acumulem em pontos específicos de acordo com distribuições de probabilidade que podem variar de acordo com as condições de caminhada de cada agente. A intenção dos agentes é chegar às portas das salas, desta forma, a função do *i-plan* é identificar qual a melhor porta a ser usada. As Fig. (13) e (14) representam a escolha de caminhada de um robô utilizando um PF, uma das bases dos *i-plans* (FOX *et al.*, 2000; REKLEITIS, 2004).



FIGURA 13: Caminhada de um Robô de acordo com a solução de um PF. FONTE: Sequential Monte Carlo Methods in Practice, 2001.

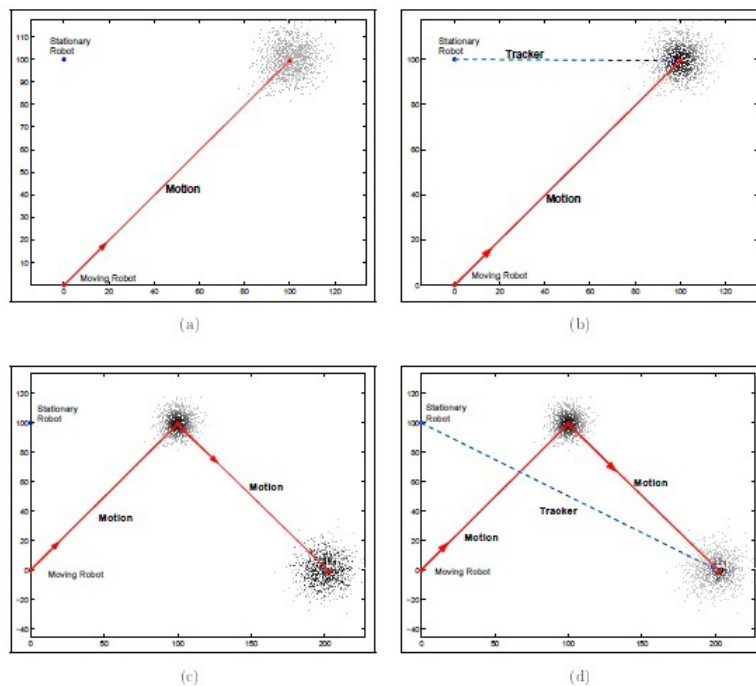


FIGURA 14: Caminhada de um Robô de acordo com a solução de um PF. FONTE: A Particle Filter Tutorial for Mobile Robot Localization, 2004.

Esses pontos de maior densidade de partículas irão representar, no ambiente parcialmente observável, portas de salas, portas de saída e o que se designa de portas fictícias, Fig. (15).




FIGURA 15: Portas Fictícias.

Tais portas fictícias são regiões definidas no ambiente de forma a manter uma caminhada coerente até a obtenção do objetivo maior de cada agente, que é conseguir encontrar uma porta de saída. As portas fictícias devem ser pré-estabelecidas de acordo com o tipo de ambiente para que o agente não fique sem caminhar, pois os desejos do agente são sempre os de encontrar portas de saída. O ambiente criado para testes deste trabalho, foi projetado para que fosse possível analisar o comportamento dos agentes perante corredores mais largos e mais estreitos, salas sem saída ou com barreiras, portas estreitas ou mais largas, salas menores e maiores e dessa forma, foi necessário a implementação de portas fictícias para que o agente não se perdesse durante o trajeto de saída. Assim, se o agente não visualiza portas reais de saídas de salas, assumirá como caminho tais portas fictícias. Ainda, mesmo que o agente consiga visualizar uma porta de saída de sala, mas também enxergue uma dessas portas fictícias, a escolha do melhor caminho será calculada pelo PF através do pyMC, levando em consideração custos e sua personalidade, ou seja, essa escolha será realizada pelo cálculo do *i-plan*. Termos como “agente visualizar” ou “agente enxergar” serão mais bem explicados na Sec. (4.2.3).

Com essas portas definidas, os outros pontos de controle para se traçar a Bézier que o agente escolherá são determinados em função da distribuição calculada pelo PF via pyMC. Essa quantidade de pontos de controle está em função da necessidade da ordem da Bézier usada em cada trecho do ambiente, para que o percurso do agente seja o mais suave possível, ou seja, para simular de modo mais próximo ao real o traçado de uma caminhada de uma pessoa, ver Fig. (16).




FIGURA 16: Escolha dos Pontos de Controle a partir do PF.

A curva Bézier traçada para a Fig. (16) será de terceira ordem, ou seja, composta por quatro pontos de controle. Ainda, a posição dos pontos das portas fictícias e das portas de saída variam de acordo com a distribuição de partículas na região.

Desta forma, pode-se dizer que em cada trecho do ambiente existem várias possibilidades de caminhada, ou seja, diversas possibilidades de Béziers que serão escolhidas em função do PF e que poderão sofrer alterações de acordo com o planejamento e personalidade de cada agente.

São justamente esses caminhos e seus custos, determinados pelo PF, que alimentarão o POMDP e a partir disso torna-se possível que o agente gere planos de caminhada, ou políticas quase ótimas, para que consiga encontrar a saída no melhor tempo com menores custos possíveis.

Essas políticas serão reavaliadas a cada parte do trajeto de acordo com o que o agente encontrar no seu caminho ou a cada vez que o agente não “aceitar” a política definida para aquele pedaço de trajeto. Esse novo plano gerado a cada interação e escolhido pelo agente pesando custos e personalidade é chamado de *i-plan*. Ou seja, uma política é formada por vários outros planos menores que são gerados no decorrer do trajeto do agente e são constantemente recalculados pelo PF.

Desta forma o esquema de movimentação dos agentes pode ser representado pelo Fluxograma a seguir, Fig. (17):

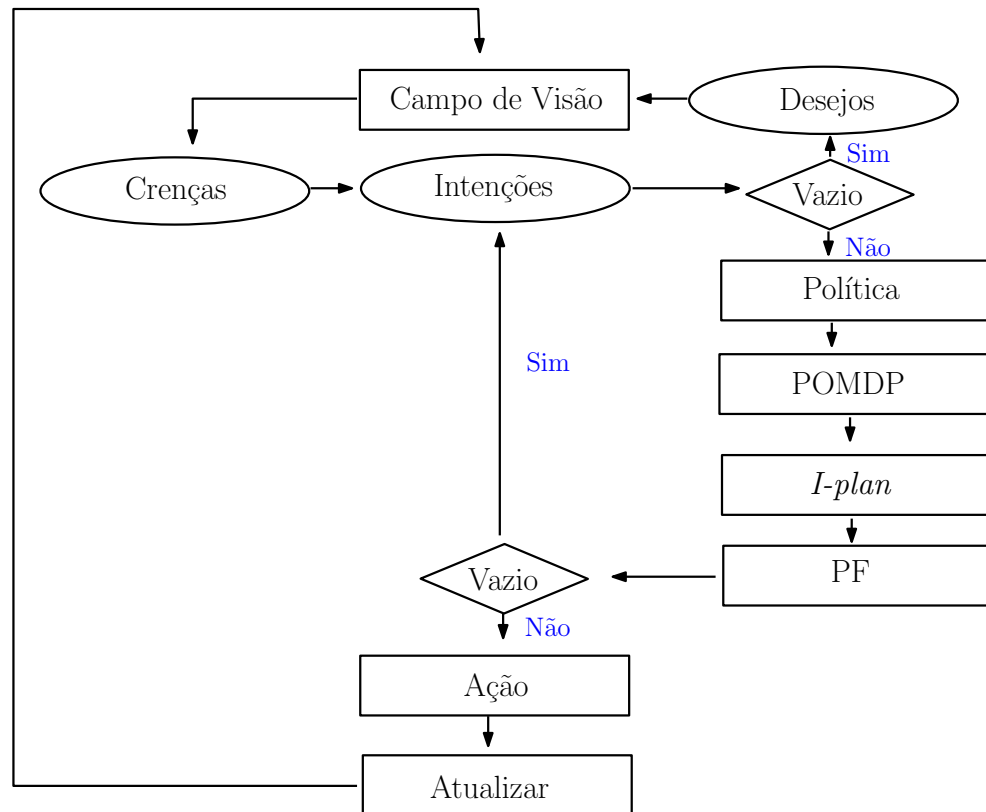


FIGURA 17: Fluxograma representativo para um agente BDI segundo um *I-plan*. Adaptado de Rens, Ferrein e Poel (2009).

Os desejos são ordenados de acordo com seus custos para um determinado caminho selecionado. O custo desses desejos são calculados a partir de uma política inicial determinada para cada agente que, em geral, é a de seguir o caminho mais curto até chegar a saída final (ou saídas parciais). Assim o agente corre seu cone de visão pelo ambiente, acessa suas crenças e define os custos para uma pilha de desejos ordenada do menor custo para o maior.

Com o desejo definido, é necessário verificar se as intenções são possíveis. Para isso, alimenta-se o POMDP com o desejo selecionado e esse resultado abastece o planejador que verifica se a intenção será ou não realizada. Se sim, o *I-plan* está definido e executa-se o PF. Se não, seleciona-se outro desejo e recalcula-se todos os passos até que o plano possa ser realizado. O agente segue o *I-plan* gerado com a intenção de menor custo.

A cada instante de tempo o agente corre o ambiente e pode mudar seus desejos e intenções. Depois desse processo é executada a ação recomendada pelo *I-plan* e as crenças são atualizadas tanto pelo que se conhece do ambiente (cone de visão) quanto pela ação que acabou de ser realizada.

Todo esse processo computacional, até esse ponto, não é visual. Os dados são

armazenados em um arquivo binário do Numpy (ver Sec. (3.9)) para que, posteriormente, o módulo de visualização escrito em Python, possa lê-lo e alimentar a animação tridimensional do VPython.

4.1.1 Memória curta e memória longa

A realização dos processos probabilísticos de decisão depende da existência de memórias.

Definiu-se que o agente possuirá uma memória longa e uma memória curta.

A memória curta é abastecida pelas informações captadas pelo agente no momento em que passa seu cone de visão pelo ambiente. Assim, o cone de visão, que é considerado um sensor, detectará a localização de paredes, de outros agentes e de portas reais ou fictícias e, de modo secundário, os pontos de controle disponíveis para a geração do traçado da movimentação (Bezier). Essas informações irão para a memória curta que alimentará os *I-plans*.

Na sequência, após a execução da movimentação, essas informações da memória curta serão transmitidas para a memória longa, que fará o papel de uma biblioteca que pode ser acessada a qualquer momento pelo agente. A importância da memória longa está no fato de que o agente poderá verificar se já passou por determinadas portas, se já desviou de obstáculos ou mesmo se já avistou outros agentes. Ainda, servirá de histórico para se analisar o caminho tomado pelo agente e o motivo das decisões tomadas para seguir determinado traçado.

Ao final de uma ação ou movimento, as informações da memória curta são passadas totalmente para a longa, e a primeira é limpa. Deste modo, o agente poderá captar novas percepções dos ambientes por onde caminha e replanejar sempre que necessário. Lembrando que todas essas observações do mundo sempre alimentarão a memória longa.

Esse armazenamento será feito no formato de dicionários do Python (FOUNDATION, 2014) para facilitar a identificação das ações registradas.

4.1.2 Combinando planejamento do POMDP com o Modelo de agente BDI

A combinação de planejamento do POMDP com o Modelo de agente BDI se dá através de um laço de controle (controlador, adaptado de Rens, Ferrein e Poel (2009)) do modelo BDI, como uma referencia, sendo modificado para acomodar o planejamento das políticas POMDP.

Incluído implicitamente nos estados de crença está um conjunto fixo de comportamentos e também um conjunto fixo de funções de custo (memória longa), sendo que esses comportamentos são os objetivos do agente em certo estado.

A ideia é que cada comportamento refere-se a um único objetivo que o agente é designado a alcançar. Cada comportamento é definido por um conjunto de planos e funções de custo que consigam fazer o agente desenvolver esse comportamento.

Cada conjunto de desejos do agente é definido por três parâmetros: o primeiro é uma referência à resolução do PF, o segundo e o terceiro fazem referência a um comportamento e estados possíveis respectivamente. As funções de custo recebem argumentos da solução do PF que se referem ao plano ao qual a função de custo está associada.

Para cada comportamento existe apenas um plano que leva à sua obtenção.

Para entender o controlador, precisa-se considerar o processo de deliberação do agente. Deliberar é o procedimento que chama e recebe informações do o campo de visão e que opera nas intenções (memória curta).

O desejo selecionado para o comportamento é aquele que consegue atingir o objetivo. O valor do desejo é estimado como o valor da política encontrada, gerado pela solução do PF.

O algoritmo testa se uma política factível pode ser gerada, ou seja, se o planejador retorna uma política de parada: quando toda saída de uma ação intencionada é ilegal, o algoritmo para, o que significa que o plano de entrada é impossível. Uma intenção com o plano sendo impossível, também é definida como uma intenção impossível.

A estratégia usada na deliberação é trabalhar com a resposta impossível, a qual é simplesmente excluída e os desejos são chamados e a próxima intenção então é selecionada para ser verificada.

Quando uma ou mais intenções são verificadas, o agente segue a intenção com maior probabilidade de ocorrência, em função da resposta do PF, para um dado plano e um certo estado. Essa intenção nem sempre será a resposta ótima, pois depende dos custos, da memória longa e da sua deliberação.

Inicialmente as intenções estão vazias, então a deliberação é chamada e as intenções são preenchidas. Sempre que o controlador precisar de um novo objetivo para executar, o algoritmo é chamado para gerar uma nova política e usar os planos para especificar a ou as intenções ativas.

A cada cumprimento de objetivo, os desejos são reativados e o procedimento se reinicia com a alimentação das intenções pelo campo de visão e pelas crenças do

agente. Então um novo objetivo é calculado, e assim por diante até que se alcance o objetivo global que é chegar a uma das portas de saída.

4.2 INTERAÇÕES ENTRE AGENTES E AMBIENTE

Além dos cálculos relacionados a Inteligência Artificial que, como já foi dito, não são visuais, é necessário construir um ambiente onde se possa observar as decisões de cada agente e consequentemente sua caminhada até as portas de saída. Nas seções a seguir será definida a parte visual deste trabalho, realizada com a utilização do módulo VPython (ver Sec. (3.9)).

4.2.1 Agente

Os agentes são estilizados como cilindros, pois desta forma é possível determinar uma altura para esses agentes de acordo com a altura do cilindro e um diâmetro definindo o diâmetro para esse cilindro. Neste trabalho serão utilizados cilindros de mesma altura e diâmetro para todos os agentes, generalizando-se o formato das pessoas. A distinção das personalidades definidas na Sec. (3.6) será dada por cores, sendo que:

- Azul: Racional.
- Verde: Custódia.
- Vermelho: Experimental.
- Laranja: Emotivo.

Esses cilindros são construídos e definidos em Python utilizando o modulo VPython da seguinte forma (SCHERER, 2014):




FIGURA 18: Representação de um Cilindro pelo VPython. FONTE: Documentação do VPython.

De acordo com a Fig. (18) a variável *pos* define o centro da base do cilindro, e consequentemente a posição do agente, a variável *axis* define a altura do cilindro e a variável *radius* define a largura do cilindro. Pelo VPython ainda é possível atribuir cores, opacidade¹ e material de constituição.

4.2.2 Paredes

Para a construção do ambiente de caminhada definiram-se as paredes por paralelepípedos ou *box*, definidos pelo VPython, da seguinte forma (SCHERER, 2014):

¹Ausência de luz. Que não é transparente.




FIGURA 19: Representação de uma caixa no VPython. FONTE: Documentação do VPython.

Como se observa na Fig. (19) e diferentemente do cilindro que define os agentes, a variável *pos* está localizada no centroide do paralelepípedo.

É possível referenciar as componentes da caixa de forma individual, definindo os vetores para os eixos x, y, z . O comprimento (ao longo do eixo x) é L , a altura (ao longo do eixo y) é H , e a largura é W (ao longo do eixo z). Por este exemplo, tem-se que o $axis = (L, 0, 0)$, ou seja, só está definido um valor para a variável x . Note-se que o eixo de uma caixa é como o eixo de um cilindro.

No paralelepípedo ou *box* também é possível definir cor, opacidade ou textura.

4.2.3 Cone de Visão

A ideia do campo de visão (FOV) tem sido usada por alguns autores (FREITAS, 2014; STEMMER *et al.*, 2005) para tentar representar como o ser humano realmente enxerga. O Departamento de Transportes da Escola Politécnica da UFBA tem feito várias pesquisas nessa área, inclusive com dados referentes a visão periférica, distância focal e compatibilização com a velocidade do pedestre ou motorista.

Neste trabalho assume-se um cone de visão que, além de simular a forma de

visualização do ser humano, será o sensor do agente. Através desse cone de visão o agente poderá detectar outros agentes, portas e demais obstáculos, conforme Fig. (20).




FIGURA 20: Agentes acoplados a seus cones de visão, fazendo a detecção de obstáculos para suas caminhadas.

Assim, a figura geométrica que representa o cone de visão é representado pelo VPython conforme Fig. (21).




FIGURA 21: Representação de um cone no VPython. FONTE: Documentação do VPython.

Da mesma forma que os outros sólidos geométricos apresentados, o cone também é definido pelas variáveis *pos* e *axis* e *radius* (SCHERER, 2014).

A variável *axis* sofre alterações quando esse cone de visão entra em contato com a parede. Por exemplo, se um agente está posicionado perpendicularmente à parede com ordenadas positivas (+X) e seu cone de visão tem um *axis* = 12cm. Se esta distância entre o agente e a parede é de 5cm tem-se que, automaticamente, esse *axis* passa a valer 5.

Desta forma, um exemplo pode ser dado pela Eq. (39) e Fig. (23).

$$ball = sphere(make_trail = True, trail_type = "curve") \quad (39)$$




FIGURA 23: Rastro de esferas. Fonte: Documentação do VPython.

O atributo *make_trail* deve ser mencionado durante a criação dos objetos em movimento, definindo para este se “true” ou se “false”, respectivamente para desenhar o rastro ou não. Já o atributo *trail_type* tem como padrão traçar curvas, mas também pode ser definido que se tracem pontos. Ainda é possível definir cores para cada rastro.

Os agentes serão representados por cilindros e estes deixarão um rastro da sua caminhada que são as curvas de Bézier. As cores desses rastros serão as mesmas de seus agentes, por exemplo, um rastro azul representará a caminhada de um agente racional e assim sucessivamente, conforme definido na Sec. (4.2.1). No módulo VPython, para se definir o estilo da curva que será traçada, a partir dos cilindros, é preciso usar o objeto *curve*. O VPython traça curvas ligando pontos com segmentos de retas. Se os pontos são suficientemente próximos uns dos outros a aparência da curva será suave.

Um dos atributos do objeto *curve* é o armazenamento de matrizes com as respectivas posições dos pontos que formam a curva. Estes atributos são armazenados como matrizes numpy. Por exemplo, pode-se desenhar um quadrado 2D apenas com o objeto *curve* da forma a seguir:

$$square = curve(pos = [(0,0), (0,1), (1,1), (1,0), (0,0)]) \quad (40)$$

Ainda é possível modificar a espessura dessas curvas e definir cores de acordo com a necessidade.

As curvas de Bézier traçadas a partir dos agentes (cilindros) são definidas utilizando o algoritmo de De Casteljau visto na Sec. (3.7.3) e com isso é possível informar para o objeto *curve* quais são os pontos que geram a curva de Bézier seguida por cada agente.

O controle da janela em que será apresentada a simulação não é peça fundamen-

tal, mas pode causar maior ou menor impacto na visualização dos resultados.

Inicialmente, há uma janela de exibição VPython chamada *cena* (SCHERER, 2014). Ao criar um objeto, imediatamente uma cena também é criada, sem a preocupação de designar algum comando para isso. Contudo, é possível criar atributos para uma cena que modifiquem a iluminação, posição das câmeras, tamanho da cena, etc. Por exemplo, a janela que será utilizada neste trabalho tem a seguinte forma:

```
cena = display(title='Movimentacao de Agentes',
x=0, y=30, width=800, height=800, center=(0,0,0),
background=(1,1,1), forward=topo, up=(0,0,1), range=camera)
```

O código anterior cria uma janela de exibição VPython de tamanho 800 por 800, com seu canto superior esquerdo na posição $x = 0$ e $y = 30$ (y é medido a partir do topo da tela), com barra de título contendo o texto “Movimentacao de Agentes”, centrada na localização $(0,0,0)$, e com uma cor de fundo branca ($\text{background}=(1,1,1)$) preenchendo a janela. Ainda, tem-se que a câmera está apontada para o centro e localizada através do vetor $(0;0,1;-6)$ dado pela variável *topo* (*forward*) e a uma distância de 40, dada pela variável (*range*) do plano dos pisos.

O objeto *vector* tem propriedades dos vetores usados muito semelhantes aos vetores usados na ciência ou engenharia. Ele pode ser utilizado em conjunto com o *numpy*.

A representação desse objeto é dada por:

$$\text{vector}(x,y,z) \quad (41)$$

É possível acessar as coordenadas individuais de um vetor, fazer diversos tipos de operações, como soma, multiplicação, normalização, calcular projeção, angulação, sendo que todos esses comandos são nativos do VPython.

4.3 PASSAGEM DE UMA BÉZIER PARA OUTRA

As curvas de Bézier definidas para os agentes possuem no mínimo quatro pontos de controle (inicial, final e dois intermediários) que fazem com que o traçado do agente seja desenhado de forma suave, sem bicos.

Como se pode observar na Fig. (24) cada porta possui um ponto de controle e outros dois (dentro e fora) alinhados a esse ponto da porta, para garantir suavidade na passagem por esses trajetos. Esses pontos, tanto o da porta quanto os de dentro e de fora, não possuem localização única. Variam de acordo com a distribuição de

partículas calculada para o respectivo movimento pelo pyMC. Isso também ocorre nas portas fictícias, pois, como são pontos de transição, precisam garantir que a passagem entre as curvas de Bézier seja suavizada.




FIGURA 24: Pontos de Controle alinhados nas portas.

Quando um agente precisa replanejar (isso pode acontecer, por exemplo, por ter um outro agente à sua frente), este tomará uma nova Bézier de acordo com a solução do PF.

4.4 CUSTOS DE MOVIMENTAÇÃO

A existência de quatro personalidades que representam o comportamento psicossocial humano de uma forma generalizada serão baseadas no trabalho da pesquisadora Behrendt, conforme já foi apresentado anteriormente, Sec. (3.6).

É necessário criar uma hipótese de valores que representem cada personalidade, para que essas possam ser transcritas matematicamente e computacionalmente. Desta forma serão adotados custos locais da caminhada dos pedestres que serão normalizados em uma escala de 0 a 1, sendo que 0 representa o custo mais baixo e 1 representa o custo mais alto para cada localidade. A conjectura é a de que custos mais baixos demonstram decisões mais tranquilas para os agentes enquanto custos mais elevados figuram decisões mais estressantes.

As variáveis que definem cada uma dessas personalidades serão apresentadas assim como os custos para as atitudes das diferentes personalidades.

- Agente Experimental:

- o agente experimental é um agente intuitivo e sempre optará pelo caminho mais curto, independente do que os agentes à sua volta estarão fazendo.
- para esse tipo de agente, o custo de passar por portas onde já passou será bem pequeno, dado por $Custo = 0,3$.
- o custo inicial das portas para esse agente será de $Custo = 0,1$.
- não segue outros agentes, escolhe seus caminhos por conta própria.
- andar por corredores extensos não lhe gerará custos.
- ao enxergar paredes, continua o percurso até encontrar um desvio, ou seja, caminhar na direção das paredes também lhe custará pouco, $Custo = 0,1$.
- retornar pelo mesmo caminho que já usou terá um custo de $Custo = 0,3$.

- Agente Custódia:

- o agente custódia é um agente preventivo e por esse motivo planejará e replanejará sempre buscando o caminho de menor custo.
- para esse tipo de agente, o custo de passar por portas onde já passou será alto, dado por $Custo = 0,7$.
- optará por portas com custo baixo.
- se à sua frente reconhecer um outro agente Custódia, tenderá a segui-lo, pois acreditará que este conheça o caminho de saída.
- o custo inicial das portas para esse agente é de $Custo = 0,1$.
- não enxergará ser uma boa escolha andar por corredores extensos, assim o custo para essa opção será de $Custo = 0,4$.
- ao enxergar paredes, procurará mudar de sala o mais rápido possível. $Custo = 0,7$.
- retornar pelo mesmo caminho que já usou terá um custo de $Custo = 0,3$.

- Agente Racional:

- o agente racional é um agente lógico e por esse motivo escolhe o caminho onde outros agentes Custódia já obtiveram sucesso.
- para esse tipo de agente, o custo de passar por portas onde já passou será alto, dado por $Custo = 0,6$.
- optará por portas com custo baixo.
- se à sua frente reconhecer um agente Custódia, tende a segui-lo, pois acreditará que este conheça o caminho de saída.

- o custo inicial das portas para esse agente será de $Custo = 0,1$
 - andar por corredores extensos não lhe gerará custos.
 - ao enxergar paredes, continuará o percurso até encontrar um desvio, ou seja, caminhar na direção das paredes também lhe custará pouco, $Custo = 0,2$.
 - retornar pelo mesmo caminho que já usou terá um custo de $Custo = 0,3$.
- Agente Emotivo:
 - o agente emotivo é um agente solidário e não gosta de caminhar sozinho. Caso esteja sozinho em uma sala o custo será de $Custo = 0,6$.
 - para esse tipo de agente, o custo de passar por portas onde já passou será mediano, dado por $Custo = 0,5$.
 - o custo das portas não influenciará sua caminhada.
 - se à sua frente reconhecer um agente Racional, tenderá a segui-lo.
 - andará por corredores extensos com custo baixo, $Custo = 0,1$.
 - quando se vir perpendicular a uma parede, tentará a modificar seu caminho procurando onde estão os outros agentes, sendo que o custo para essa visão das paredes será de $Custo = 0,2$.
 - retornar pelo mesmo caminho que já usou terá um custo de $Custo = 0,3$.

Hipóteses de velocidades médias genéricas globais para cada personalidade:

- Agentes Experimentais: 1,6 m/s
- Agentes Racionais: 1,4 m/s
- Agentes Custódias: 1,34 m/s
- Agentes Emotivos: 1,1 m/s

Como a característica geral para todos os agentes é a de uma situação de evacuação do ambiente em função de um iminente perigo que não tem sua localização ou natureza detectados pelos agentes, estes seguirão uma equação que relaciona custos e velocidade, sendo que a velocidade dos agentes no ambiente é diretamente proporcional aos custos, ou seja, quanto maior for o custo maior será a sua velocidade. Em outras palavras, quanto mais o agente demorar para encontrar uma saída maior será seu nível de estresse. Como já foi descrito na Sec. (3.6), isso representa a

característica psicológica de aumentar a velocidade quando ocorre um aumento dos níveis de estresse gerados pelo pânico.

No próximo capítulo serão apresentados os resultados da aplicação desta metodologia.

5 RESULTADOS

As imagens a seguir são representativas de cinquenta simulações, utilizando o mesmo ambiente de testes, idealizado para representar salas, corredores, obstáculos e portas em diferentes tamanhos e composições, sendo que as quatro identidades serão alocadas nesse ambiente em diversas combinações. Supõe-se que seja tocado uma sirene e os agentes comecem a evacuar o ambiente. Dessa forma, os resultados conterão uma análise crítica referente as variáveis psicocomportamentais em casos de agentes com algum nível de estresse e uma análise numérica referente a tempos de evacuação, quantidades de portas de saída do ambiente e portas internas escolhidas, velocidades médias e distâncias percorridas por cada personalidade.

5.1 QUATRO PERSONALIDADES

A análise da evacuação dos agentes é iniciada tendo como hipótese a existência de dois agentes com cada personalidade.




FIGURA 25: Hipótese de dois agentes de cada personalidade contidos no ambiente de testes.

Em azul tem-se os Racionais, em verde tem-se os Custódia, em laranja tem-se

os Emotivos e em vermelho tem-se os Experimentais, conforme Sec. (4.2.1). Dessa forma, a planta com as posições iniciais de cada agente é dada pela Fig. (25).

Observa-se na Fig. (26) o percurso total da caminhada de oito agentes distribuídos igualmente entre as quatro personalidades. Esses caminhos ilustrados são o resultado de uma avaliação do comportamento médio entre os agentes durante cinquenta simulações, com algumas variações entre os caminhos escolhidos e portas usadas.

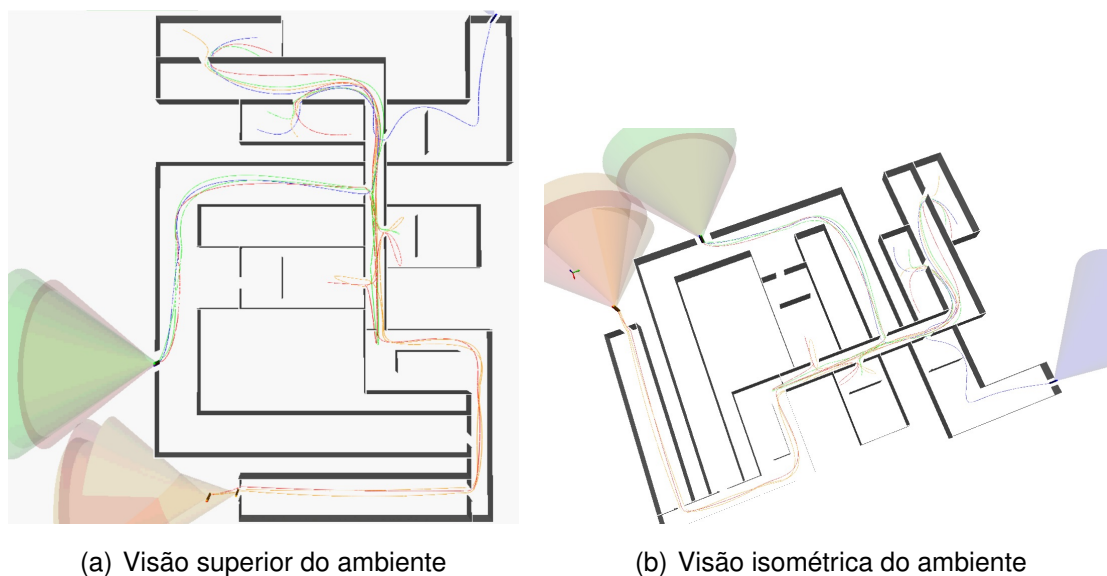


FIGURA 26: Visualizações do ambiente.

Qualitativa) Para a realização de uma análise qualitativa, utiliza-se como amostra um vídeo de vinte segundos representativo da resposta estatística, gerado a partir de uma das simulações. Através da linha do tempo proporcionada por esse vídeo pode-se observar que:

1. Início do trajeto

A saída de todos os agentes das salas 1 e 2 se dá de forma lenta, pois todos estão ainda com custos baixos, ou seja, baixos níveis de estresse. Com o decorrer da caminhada e quanto mais tempo esses agentes demoram para encontrar as portas de saída do ambiente, maiores são esses custos e consequentemente, maiores são as velocidades.

Conforme Fig. (27), retirada de um vídeo com tempo total de vinte segundos, feito a partir de uma das simulações realizada para esse caso, em três segundos de visualização se observa que há alguns choques entre os agentes nas saídas das portas. Tais choques são naturais em situações de estresse, segundo a bibliografia analisada (STEINBERG, 2005; PREDTETSCHENSKI; MILINSKI, 1971; HELBING; MOLNÁR, 1995).



FIGURA 27: Choques entre agentes.

2. Observa-se, Fig. (28), a escolha do agente Racional que saiu da sala 2, em entrar na porta D do corredor.




FIGURA 28: Decisão do agente Racional (sala 2) ao entrar na porta D. Tempo: 3s.

Tal decisão provavelmente é tomada porque o custo para ele tentar passar por uma porta por onde ainda não passou é pequeno.

3. De acordo com a Fig. (29), observa-se que esse mesmo agente Racional (sala 2) se encaminha para sair pela porta 2 de saída do ambiente, pois a sua escolha o levou a um corredor sem obstáculos, o direcionando para tal saída.

O agente Racional que saiu da sala 1 optou por testar a porta C, provavelmente pelo baixo custo de entrar por portas que ainda não entrou. Também escolheu tentar passar pelo obstáculo, possivelmente por ter um custo baixo para tal atitude. Essas decisões direcionam sua saída do ambiente pela porta 1.

O agente Emotivo que saiu da sala 2, o agente Experimental que saiu da sala 2 e o agente Custódia que saiu da sala 2, resolveram testar as portas F, E e H, respectivamente, mas os três avistaram um obstáculo e decidiram voltar para o corredor. Com relação ao agente Experimental, a opção se deu por essa sala não possuir saída. Já os outros dois agentes, possivelmente tomaram essa decisão por terem custos altos em tentar passar por obstáculos.




FIGURA 29: Decisão dos agentes Racionais (sala 1 e 2) e dos agentes Emotivo, Experimental e Custódia (sala 2). Tempo: 9s.

4. O agente Custódia (sala 2), após desistir de seguir caminho pela porta H, volta para a porta D e está se direcionando para sair do ambiente pela porta 1, Fig. (30). O outro agente Custódia (sala 1) testou a porta E, mas também decidiu voltar em direção ao corredor, retomando sua caminhada em direção a porta D. Possivelmente essa escolha tenha sido feita porque o custo para um agente Custódia retornar por caminhos onde já passou não é muito alto e como essa identidade foi idealizada para que esses agentes fossem bons planejadores, a saída do ambiente passando pela porta D, sem obstáculos, provavelmente lhe garante custos mais baixos.




FIGURA 30: Decisões dos agentes no tempo: 13s.

O agente Emotivo que saiu da sala 1 resolveu testar a porta E, mas percebe que a sala não tem saída e retorna ao corredor.

O agente Experimental (sala 2) que havia testado a porta E se encaminha até a porta H, seguido pelo agente Emotivo (sala 2) que saiu da porta F. O agente Experimental tem custos baixos para a maior parte de suas atitudes, por esse motivo parece natural que ele teste o ambiente até encontrar a saída. O agente Emotivo que o segue, possivelmente toma essa decisão para não permanecer sozinho, devido ao alto custo caso contrário.

O agente Experimental (sala 1) que testou a porta H, retornou para a porta F. Como já foi comentado, essa personalidade tem custos baixos para testar o ambiente.




FIGURA 31: Decisão dos agentes no tempo: 15s.




FIGURA 32: Decisão dos agentes no tempo: 19s.

5. O agente Custódia (sala 1) se direciona para a porta 2, Fig. (31). O agente Experimental (sala 1) que retornou da porta F também se direciona para a porta D, provavelmente para sair pela porta 2.

Os agentes Emotivo (sala 2) e Experimental (sala 2) que passaram pela porta H escolhem sair pela porta J e sair do ambiente pela porta 3.

O agente Emotivo (sala 1) que retornou da sala E se direciona para a porta H. Como decidiu permanecer sozinho durante alguns momentos do percurso, terá que tomar as decisões para encontrar a porta de saída sem seguir outros agentes. Esse fato faz com que seus custos aumentem e, com isso, sua velocidade também será maior.

6. O agente Emotivo (sala 1) que passou pela porta H se direciona para a porta J para sair do ambiente pela porta 3, conforme Fig. (32).

O agente Experimental (sala 1) que retornou da porta F, decide testar a porta D e sair do ambiente pela porta 2.

Quantitativa) Após cinquenta simulações, foi realizada uma análise em cima do tempo de evacuação de cada uma das personalidades.




FIGURA 33: Tempo de Evacuação das quatro personalidades.

Observa-se na Fig. (33), que o tempo de evacuação dos agentes Custódias é o melhor dentre as quatro personalidades, com média de 25,49 s. Lembrando que o ambiente de testes para esse caso possui dois agentes de cada personalidade. Assim, esse tempo médio representa a evacuação de cem agentes

Custódias (N=100). Possivelmente esse bom resultado se deva por estes serem agentes planejadores e, além disso, têm a característica de seguirem outros agentes Custódias, o que faz com que todo o grupo descubra a melhor saída rapidamente.

Os agentes Emotivos são o segundo grupo em tempo de evacuação, com média de 25,88 s. Acredita-se que esse fato ocorra pelo fato dessa personalidade ter custos altos ao caminhar sozinha, decidindo seguir outros grupos e saindo rapidamente junto com eles.

O terceiro grupo em tempo de evacuação é o grupo dos agentes Racionais. Essa personalidade, assim como os agentes Custódias possui custos altos ao testar caminhos, além disso, quando agentes Racionais encontram agentes Custódias, tendem a segui-los, o que pode acelerar o tempo de evacuação dessa personalidade. Um fato que deve ser observado é o de que, mesmo com um tempo médio de evacuação maior do que o tempo médio dos agentes Emotivos, essa personalidade possui um desvio padrão menor do que todas as outras personalidades.

Os agentes Experimentais, por terem custos baixos quando testam caminhos, provavelmente acabam demorando a encontrar as portas de saída.

Fazendo uma contagem do número de vezes que cada personalidade optou por sair pelas portas 1, 2 e 3 de saída do ambiente de testes, nas cinquenta simulações realizadas, obteve-se os seguintes resultados de acordo com a Fig. (34):




FIGURA 34: Portas de saída do ambiente de testes mais utilizadas por cada personalidade.

Se for analisado todas as portas do ambiente e portas de saída, tem-se os seguintes resultados de acordo com a Fig. (35):




FIGURA 35: Número de vezes que cada porta do ambiente de testes é utilizada por cada personalidade.

Ainda, é possível obter resultados quanto a velocidade média dos agentes e distâncias percorridas por cada personalidade.

Desta forma, as velocidades médias calculadas com a realização de cinquenta simulações, contendo dois agentes de cada personalidade em cada simulação, ou seja, cem agentes de cada grupo no total, são dadas de acordo com a Fig. (36).




FIGURA 36: Velocidades Médias e Desvio padrão, para cada personalidade.

Observa-se que, em uma linha crescente, da velocidade média menor para a maior, que tem-se os agentes Experimentais, os agentes Racionais, os agentes Emotivos e os agentes Custódias. É preciso lembrar que a velocidade pode sofrer alterações de acordo com os custos da caminhada. Esses mesmos custos representam o nível de estresse dos agentes.




FIGURA 37: Distâncias Médias percorridas e Desvio padrão, para cada personalidade.

Verifica-se, em uma linha decrescente, da maior distância média percorrida para a menor, que tem-se os agentes Emotivos, os agentes Custódias, os agentes Experimentais e os agentes Racionais.

Relacionando as velocidades médias, as distâncias percorridas, o tempo de evacuação e lembrando que cada agente possui custos para tomar uma ação, as tendências encontradas para esse ambiente de testes, com essas combinações de agentes e suas posições iniciais predefinidas, foram compatíveis com as hipóteses impostas na metodologia.

5.2 AMBIENTE COM ÚNICA PERSONALIDADE

Nas próximas seções será feita uma análise crítica qualitativa das escolhas de cada personalidade. Essa apreciação é feita baseada em cinquenta simulações de cada um dos ambientes de testes analisados, sendo que o comportamento apresentado nas figuras a seguir correspondem a uma média estatística representativa, observada nessas simulações.

A realização de simulações em ambientes contendo um único tipo de personalidade serviu de controle para a avaliação dos ambientes com múltiplas personalidades, visto que uma situação desse tipo é praticamente impossível de ocorrer.

O ambiente e as posições iniciais de cada agente são dados de acordo com a Fig. (38).




FIGURA 38: Ambiente Geral e Posição inicial dos Agentes.

5.2.1 Agentes Racionais

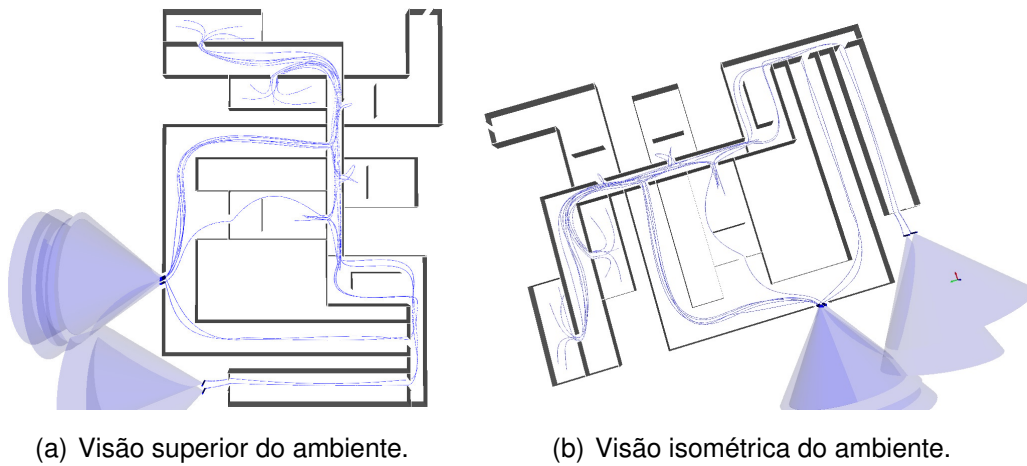


FIGURA 39: Ambiente composto apenas por agentes Racionais.

O agente Racional é um agente que anda com poucos custos por corredores extensos e, em contrapartida, tem um custo alto por passar por portas que já utilizou, sendo que esse custo é acrescido se encontrar obstáculos. Por esse motivo, observa-se, Fig. (39), que poucos desses agentes entraram na porta C. E ao fazerem isso, encontraram uma parede que os fizeram desistir daquela sala. O mesmo ocorre com os agentes que optaram pela porta E.

Já os agentes que fizeram a escolha pela porta D e viram à sua frente apenas um grande corredor, sem obstáculos, decidiram seguir por ele até a porta de saída.

Seguindo a mesma ideia, apenas um único agente optou por seguir caminho ao entrar na porta F, sendo que esse também encontrou uma porta de saída.

Os demais agentes seguiram pelos corredores e foram distribuídos entre a porta I e porta J, pelas quais passaram e não encontraram obstáculos, o que os levou à porta de saída.

5.2.2 Agentes Experimentais

Os agentes experimentais são agentes testadores, ou seja, os custos relacionados a entrar por uma porta e sair pela mesma porta e os custos relacionados à tentativa de passar por cantos, caso avistarem paredes, são baixos. Isso fica visível na Fig. (40) quando se verifica que, logo na porta C, dois agentes identificaram um obstáculo e mesmo assim decidiram seguir por aquele caminho. Na porta E, também se pode observar que os agentes que entraram por ela testaram o caminho, chegando bem próximo aos cantos do obstáculo.

Dois agentes entraram pela porta F, sendo que o agente que resolveu testar o canto do obstáculo acabou encontrando a saída rapidamente enquanto o outro agente desistiu ao ver o obstáculo. Lembrando que, para o agente Experimental, voltar por portas que já passou ou enfrentar obstáculos têm custos baixos.

Os demais se distribuíram pelas outras salas e corredores sendo que todos esses os levavam a portas de saída com poucos custos.




FIGURA 40: Ambiente composto apenas por agentes Experimentais.

5.2.3 Agentes Custódias

O agente Custódia é um agente planejador, parecido com o agente Racional, mas com custos mais altos para passar por portas onde já passou, ou quando avista obstáculos. Também possui um custo médio por permanecer em corredores ou retornar por caminhos onde já passou. Desta forma, todos esses custos o obriga a planejar mais do que os outros agentes.

Observa-se, Fig. (41), que apenas dois agentes optaram por entrar porta C e logo desistiram, pois o custo de analisar o obstáculo, passar por ele e depois ter que retornar seria muito alto.

Quatro agentes foram rapidamente bem sucedidos ao escolherem a porta D. Lembrando que a passagem de agentes Custódias por portas que eles ainda não utilizaram tem um custo baixo e, se à frente deles não houver obstáculos, provavelmente optarão por esse caminho, pois retornar seria muito custoso.

Alguns agentes ainda testaram a porta E e a passagem pela parede, mas como essa sala não tem saída, logo abandonaram o plano seguindo pelo corredor.

Três agentes entram na porta F e seguem pelo corredor até encontrar a saída, também demonstrando a capacidade de planejamento desta personalidade.

Apenas dois agentes dos dez que iniciaram a simulação demoram para encontrar a saída, sendo que um deles opta pela porta I e o último opta pela porta J.





FIGURA 41: Ambiente composto apenas por agentes Custódias.

5.2.4 Agentes Emotivos

Uma das principais características do agente Emotivo é a de procurar outros agentes. Também pode ser considerado um agente medroso, devido ao fato de lhe custar

quando encontra obstáculos. Contudo, o fato de entrar em salas novas não lhe custa e se isso lhe acarretar em sucesso, ou seja, não encontrar obstáculos, provavelmente seguirá por esse caminho até a saída. É o que se observa na Fig. (42).



(a) Visão superior do ambiente.

(b) Visão isométrica do ambiente.

FIGURA 42: Ambiente composto apenas por agentes Emotivos.

Ao testarem a porta C, porta E e porta F e encontrar obstáculos, rapidamente os agentes Emotivos desistem desse trajeto, voltando ao corredor e procurando outros agentes e outros trajetos. Apenas um agente entrou na porta F e decidiu seguir em frente, provavelmente por ter chegado ao canto do obstáculo e identificado que à frente o corredor estaria livre. Nesse caso, como o custo de retornar é alto, esse agente resolveu manter o plano e seguir até encontrar a porta de saída.

Os demais agentes optaram:

- pela porta E, que os levava à saída com baixo custo, seguindo apenas pelo corredor;
- pela porta H, pois o custo de retornar era alto, sendo que a maioria deles saiu pela porta J, ou seja, eles optaram em se manter no corredor, juntos, até passarem por uma porta onde não haveria obstáculos.

5.3 AMBIENTE DESBALANCEADO

Em cada um dos casos que serão analisados na sequência, haverá uma ou outra personalidade com agentes a mais, fazendo com que o número total de agentes de cada personalidade não esteja equilibrado. Desta forma, procura-se analisar tendências de comportamento quando se tem em um grupo agentes de um único tipo em maior número e verificar se tal personalidade dominará os resultados.

As imagens a seguir são representativas de cinquenta simulações, utilizando o mesmo ambiente de testes, idealizado para representar salas, corredores, obstáculos e portas em diferentes tamanhos e composições.

5.3.1 Racionais em maior número

Nessa seção, a distribuição das personalidades é parecida com a Sec. (5.1) contudo, a análise da evacuação dos agentes é iniciada tendo como hipótese a existência, tanto na sala 1 como na sala 2, de um agente a mais de personalidade Racional. Assim, dos dez agentes presentes em cada simulação, quatro são de personalidade Racional.

A seguir será apresentada a avaliação qualitativa, seguida pela avaliação quantitativa dos resultados.

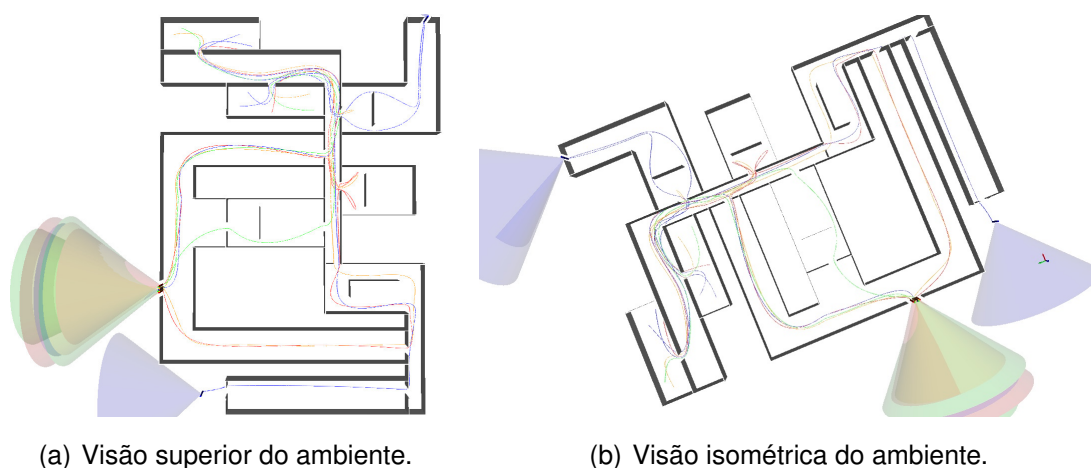
Qualitativa) Como já foi dito, o custo para um agente Racional passar por portas onde já passou é alto, isso faz com que, ao entrar em salas, esse agente tente encontrar uma porta de saída. Esse fato pode ser observado, Fig. (43), na porta C, na porta D e na porta J.

Observa-se também que os agentes Emotivos optaram em não permanecer sozinhos durante a maior parte do trajeto.

Os agentes Experimentais, como de costume, testaram o ambiente, voltando por caminhos quando necessário, como pode-se observar com o agente Experimental que entrou na porta E e retornou até a porta D e nesse caso, o agente Emotivo o seguiu para que não houvesse acréscimo em seus custos por permanecer sozinho.

Já os agentes Custódia, como bom planejadores e evitando obstáculos, optaram pela porta D e porta F, obtendo sucesso até a saída do ambiente.

Um agente Emotivo tentou seguir a decisão dos dois agentes Racionais que escolheram a porta C, contudo, ao avistar o obstáculo mudou seu plano e voltou a seguir os outros agentes que estavam no corredor.



(a) Visão superior do ambiente.

(b) Visão isométrica do ambiente.

FIGURA 43: Ambiente composto por um número maior de agentes Racionais.




FIGURA 44: Tempos médios de evacuação das quatro personalidades em um ambiente com maior número de agentes Racionais.

Quantitativa) Após cinquenta simulações contendo dez agentes em cada uma, ou seja, com agentes Experimentais, Custódias e Emotivos ($N=100$) e duzentos agentes Racionais ($N=200$) no total, foi realizada uma análise quantitativa em cima do tempo de evacuação de cada uma das personalidades. Observa-se na Fig. (44), que o tempo de evacuação dos agentes Custódias foi melhor entre as quatro personalidades, 24,92 s, possivelmente por estes serem agentes planejadores e, além disso, têm a característica de seguir outros agentes Custódias, o que faz com que todo o grupo descubra a melhor saída rapidamente.

O segundo melhor tempo médio de Evacuação é, justamente, dos agentes Racionais, 25,54 s. Acredita-se que mesmo esses estando em maior número e, talvez por esse motivo, tenham seguido agentes Custódias e construídos planos eficientes.

Na sequência, tem-se os agentes Emotivos e acredita-se que seja pelo fato dessa personalidade ter custos altos ao caminhar sozinha, decidindo seguir outros grupos e saindo rapidamente junto com eles.

O maior tempo médio de evacuação ficou para os agentes Experimentais que, como já foi citado, são agentes testadores do ambiente, com custos baixos e consequentemente, entram em um número maior de salas antes de saírem do ambiente de testes.

Fazendo uma contagem do número de vezes que cada personalidade optou por sair pelas portas 1, 2 e 3 de saída do ambiente de testes, nas cinquenta simulações realizadas, obteve-se os seguintes resultados de acordo com a Fig. (45):




FIGURA 45: Portas de saída do ambiente de testes mais utilizadas por cada personalidade.

Se for analisado todas as portas do ambiente, opcionais dos corredores e salas e portas de saída, tem-se os seguintes resultados de acordo com a Fig. (46):




FIGURA 46: Número de vezes que cada porta do ambiente de testes é utilizada por cada personalidade.

Ainda, é possível obter resultados quanto a velocidade média dos agentes e médias de distâncias percorridas por cada personalidade.

Desta forma, de acordo com a Fig. (47), as velocidades médias calculadas com a realização de cinquenta simulações, contendo dois agentes de cada personalidade em cada simulação, ou seja, cem agentes de cada grupo no total, são:




FIGURA 47: Velocidades Médias e Desvio padrão, para cada personalidade.

Observa-se que, em uma linha crescente, da velocidade média menor para a maior, que tem-se os agentes Experimentais, os agentes Racionais, os agentes Emotivos e os agentes Custódias. É preciso lembrar que a velocidade pode sofrer alterações de acordo com os custos da caminhada. Esses mesmos custos representam o nível de estresse dos agentes. Esses resultados são semelhantes e seguem a mesma ordem dos resultados obtidos com o ambiente equilibrado com as quatro personalidades.




FIGURA 48: Distâncias Médias percorridas e Desvio padrão, para cada personalidade.

Verifica-se, em uma linha decrescente, Fig. (48), da maior distância média percorrida para a menor, que tem-se os agentes Experimentais, os agentes Emotivos, os agentes Custódias e os agentes Racionais. Os agentes Racionais mantiveram a menor média de distâncias percorridas, comparado ao ambiente de testes equilibrado, mesmo em simulações onde o número de agentes Racionais é maior do que o número de agentes das outras personalidades.

5.3.2 Experimentais em maior número

Nessa seção, a análise da evacuação dos agentes é iniciada tendo como hipótese a existência, tanto na sala 1 como na sala 2, de um agente a mais de personalidade Experimental. Assim, dos dez agentes presentes em cada simulação, quatro são de personalidade Experimental.

As análises qualitativas e quantitativas da realização de cinquenta simulações realizadas em um ambiente desbalanceado contendo um número maior de agentes Experimentais segue abaixo:

Qualitativa) Os dois agentes Custódia optaram por entrar primeiramente na porta E, mas esta continha obstáculo e o custo de tentar passar por ele é, para esse agente, alto. Desta forma, um deles optou por sair sem analisar o restante da sala e voltando para o corredor entrou na porta F. Como este ainda não havia somado custos

para analisar obstáculos, nessa sala ele optou por tentar passar pela barreira e foi bem sucedido encontrando a saída. O outro agente Custódia que entrou na porta E, aumentou seus custos analisando o obstáculo. Dessa forma, ao sair da sala, voltou pelo corredor e escolheu a porta D que não possuía obstáculos no seu interior, encontrando a saída rapidamente.

O agente Experimental também entrou na porta E, contudo para esse tipo de agente o custo de tentar passar por obstáculos é baixo.

Dos dez agentes presentes no ambiente, seis saíram passando pela porta D, sendo que os Emotivos mantiveram-se seguindo o grupo, pois sair dele é muito custoso.

Sendo agentes testadores, os Experimentais também obtiveram sucesso saindo pela porta I e porta J.

Um dos agentes Racionais entrou na porta F, avistou um obstáculo, o que, possivelmente lhe gerou um custo alto, e decidiu voltar ao corredor, que lhe traria um custo menor, até encontrar a saída passando pela porta J.

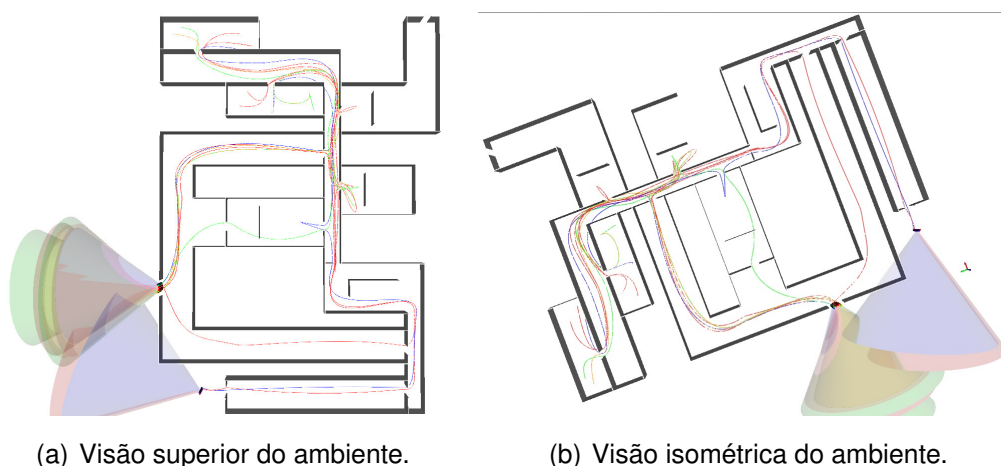


FIGURA 49: Ambiente composto por um número maior de agentes Experimentais.




FIGURA 50: Tempos médios de evacuação das quatro personalidades em um ambiente com maior número de agentes Experimentais.

Quantitativa) Após cinquenta simulações contendo dez agentes em cada uma, ou seja, com agentes Racionais, Emotivos e Custódias ($N=100$) e duzentos agentes Experimentais ($N=200$) no total, foi realizada uma análise quantitativa em cima do tempo de evacuação de cada uma das personalidades. Observa-se na Fig. (31), que o tempo de evacuação dos agentes Custódias foi melhor entre as quatro personalidades, 24,69 s.

O segundo melhor tempo médio de Evacuação é a dos agentes Emotivos, 25,36 s. Possivelmente esse tempo seja decorrente da capacidade dos agentes Emotivos seguir outros agentes e com isso obter bons planos de fuga.

Na sequência, tem-se os agentes Racionais, trocando de posição em tempo de evacuação se comparada as médias entre o ambiente com mais agentes Experimentais e o ambiente com mais agentes Racionais.

O maior tempo médio de evacuação ficou para os agentes Experimentais que, como já foi citado, além de serem agentes testadores, estavam em maior número no ambiente de testes.

Fazendo uma contagem do número de vezes que cada personalidade optou por sair pelas portas 1, 2 e 3 de saída do ambiente de testes, nas cinquenta simulações realizadas, obteve-se os seguintes resultados de acordo com a Fig. (51):




FIGURA 51: Portas de saída do ambiente de testes mais utilizadas por cada personalidade.

Se for analisado todas as portas do ambiente, opcionais dos corredores e salas e portas de saída, tem-se os seguintes resultados de acordo com a Fig. (58):




FIGURA 52: Número de vezes que cada porta do ambiente de testes é utilizada por cada personalidade.

Ainda, é possível obter resultados quanto a velocidade média dos agentes e médias de distâncias percorridas por cada personalidade.

Desta forma, de acordo com a Fig. (53), as velocidades médias calculadas com a realização de cinquenta simulações, contendo dois agentes de cada personalidade em cada simulação, ou seja, com agentes de cada grupo no total, são:




FIGURA 53: Velocidades Médias e Desvio padrão, para cada personalidade.

Observa-se que, em uma linha crescente, da velocidade média menor para a maior, que tem-se os agentes Racionais, os agentes Custódias, os agentes Experimentais e os agentes Emotivos. É preciso lembrar que a velocidade pode sofrer alterações de acordo com os custos da caminhada. Esses mesmos custos representam o nível de estresse dos agentes.




FIGURA 54: Distâncias Médias percorridas e Desvio padrão, para cada personalidade.

Verifica-se, em uma linha decrescente, Fig. (54), da maior distância média percorrida para a menor, que tem-se os agentes Experimentais, os agentes Emotivos, os agentes Racionais e os agentes Custódias. Os resultados das distâncias médias percorridas por cada personalidade são semelhantes ao ambiente onde havia mais agentes Racionais, apenas tendo uma troca de posições entre os agentes Racionais e Custódias.

5.3.3 Custódia em maior número

Nessa seção, a análise da evacuação dos agentes é iniciada tendo como hipótese a existência, tanto na sala 1 como na sala 2, de um agente a mais de personalidade Custódia. Assim, dos dez agentes presentes em cada simulação, quatro são de personalidade Custódia.

As análises qualitativas e quantitativas da realização de cinquenta simulações realizadas em um ambiente desbalanceado contendo um número maior de agentes Custódias segue abaixo:

Qualitativa) A característica de que os agentes Custódias, quando avistam outros agentes Custódias, tendem a segui-los pode ser observada na Fig. (55) assim como a característica de que os agentes Emotivos tendem a permanecer em grupo. Essa característica de “rebanho” é muitas vezes citada por Quarantelli (1957).

Nessa figura, também fica evidente que, observar a existência de obstáculos, em geral, faz com que os agentes desistam do caminho e optem por outras salas. As saídas alternativas são muitas vezes ignoradas ou não utilizadas de forma eficiente em situações de fuga (KEATING, 1982; ELLIOTT; SMITH, 1993). Em todas as simulações apresentadas até o momento, independente das personalidades analisadas, pode-se verificar que a saída passando pela porta C é quase inutilizada. As análises quantitativas confirmam essa tendência.

De acordo com a Fig. (55), todos os agentes optaram por permanecer um tempo maior nos corredores à opção de entrarem em salas. Isso se deve ao fato de que suas velocidades, em situações de estresse, estão alteradas (PREDTETSKENSKI; MILINSKI, 1971).




FIGURA 55: Ambiente composto por um número maior de agentes Custódias.




FIGURA 56: Tempos médios de evacuação das quatro personalidades em um ambiente com maior número de agentes Experimentais.

Quantitativa) Após cinquenta simulações contendo dez agentes em cada uma, ou seja, com agentes Racionais, Emotivos e Experimentais ($N=100$) e duzentos agentes Custódias ($N=200$) no total, foi realizada uma análise quantitativa em cima do tempo de evacuação de cada uma das personalidades. Observa-se na Fig. (56), que o tempo de evacuação dos agentes Custódias foi melhor entre as quatro personalidades, 25,15 s, mesmo esse agente estando em maior quantidade do que os outros.

O segundo melhor tempo médio de Evacuação é a dos agentes Racionais, 25,45 s. Novamente intercalando de posição com os agentes Emotivos, que ficaram com o terceiro tempo médio de evacuação, 25,81, bem próximo dos agentes Racionais.

O maior tempo médio de evacuação, como já observado também nas outras simulações, ficou para os agentes Experimentais, 26,68.

Fazendo uma contagem do número de vezes que cada personalidade optou por sair pelas portas 1, 2 e 3 de saída do ambiente de testes, nas cinquenta simulações realizadas, obteve-se os seguintes resultados de acordo com a Fig. (57):




FIGURA 57: Portas de saída do ambiente de testes mais utilizadas por cada personalidade.

Se for analisado todas as portas do ambiente, opcionais dos corredores e salas e portas de saída, tem-se os seguintes resultados de acordo com a Fig. (58):




FIGURA 58: Número de vezes que cada porta do ambiente de testes é utilizada por cada personalidade.

Ainda, é possível obter resultados quanto a velocidade média dos agentes e médias de distâncias percorridas por cada personalidade.

Desta forma, de acordo com a Fig. (59), as velocidades médias calculadas com a realização de cinquenta simulações, contendo dois agentes de cada personalidade em cada simulação, ou seja, com agentes de cada grupo no total, são:




FIGURA 59: Velocidades Médias e Desvio padrão, para cada personalidade.

Observa-se que, em uma linha crescente, da velocidade média menor para a maior, que tem-se os agentes Experimentais, os agentes Custódias, os agentes Racionais e os agentes Emotivos. Os agentes Custódias, comparados ao ambiente de testes onde havia mais agentes Experimentais, manteve a segunda menor velocidade média. Possivelmente esse fato se deva a esses agentes serem bons planejadores e desta forma seus custos não se tornam muito elevados e por esse motivo mantêm velocidades médias mais baixas do que as de outros agentes. É preciso lembrar que a velocidade pode sofrer alterações de acordo com os custos da caminhada. Esses mesmos custos representam o nível de estresse dos agentes.




FIGURA 60: Distâncias Médias percorridas e Desvio padrão, para cada personalidade.

Verifica-se, em uma linha decrescente, Fig. (60), da maior distância média percorrida para a menor, que tem-se os agentes Experimentais, os agentes Emotivos, os agentes Racionais e os agentes Custódias. Os resultados das distâncias médias percorridas por cada personalidade são semelhantes ao ambiente onde havia mais agentes Racionais e ao ambiente onde havia mais agentes Experimentais.

5.3.4 Emotivos em maior número

Nessa seção, a análise da evacuação dos agentes é iniciada tendo como hipótese a existência, tanto na sala 1 como na sala 2, de um agente a mais de personalidade Emotivos. Assim, dos dez agentes presentes em cada simulação, quatro são de personalidade Custódia.

As análises qualitativas e quantitativas da realização de cinquenta simulações realizadas em um ambiente desbalanceado contendo um número maior de agentes Emotivos segue abaixo:

Qualitativa) Como já foi demonstrado nas outras seções, apenas o agente Experimental optou sair pela porta C, lembrando que os custos para esse agente passar por obstáculos é bem pequeno.

Em dois momentos, dois agentes Emotivos decidiram se separar do grupo, mas em seguida entraram novamente nos grupos mais próximos, visto que para esse agente é custoso permanecer sozinho.

Sete dos dez agentes simulados saíram passando pela porta D e pela porta F. Estas são as portas intermediárias do ambiente, sendo que, ao se passar pela porta D, não há mais obstáculos até a saída, o que faz com que o custo para a maioria dos agentes seja pequeno. Já na porta F há um obstáculo, mas os agentes que decidem por ela, precisam analisar o custo de retornar. Se este for maior do que o custo de passar pelo obstáculo, provavelmente tomarão essa decisão. É o que ocorre na Fig. (61).

Os dois agentes que optam pela porta I também não acrescem muito a seus custos, pois, como já foi escrito, andar por corredores tem custo baixo a todos.




FIGURA 61: Ambiente composto por um número maior de agentes Emotivos.




FIGURA 62: Tempos médios de evacuação das quatro personalidades em um ambiente com maior número de agentes Experimentais.

Quantitativa) Após cinquenta simulações contendo dez agentes em cada uma, ou seja, cem agentes Racionais, Custódias e Experimentais ($N=100$) e duzentos agentes Emotivos ($N=200$) no total, foi realizada uma análise quantitativa em cima do tempo de evacuação de cada uma das personalidades. Observa-se na Fig. (62), que o tempo de evacuação dos agentes Emotivos foi melhor entre as quatro personalidades, 25,44 s, mas com uma diferença de apenas um centésimo de segundo em relação ao tempo de evacuação médio dos agentes Custódias.

O terceiro menor tempo médio de evacuação foi o dos agentes Racionais, 26,08.

O maior tempo médio de evacuação, como já observado também nas outras simulações, ficou para os agentes Experimentais, 27,78.

Fazendo uma contagem do número de vezes que cada personalidade optou por sair pelas portas 1, 2 e 3 de saída do ambiente de testes, nas cinquenta simulações realizadas, obteve-se os seguintes resultados de acordo com a Fig. (63):




FIGURA 63: Portas de saída do ambiente de testes mais utilizadas por cada personalidade.

Se for analisado todas as portas do ambiente, opcionais dos corredores e salas e portas de saída, tem-se os seguintes resultados de acordo com a Fig. (64):




FIGURA 64: Número de vezes que cada porta do ambiente de testes é utilizada por cada personalidade.

Ainda, é possível obter resultados quanto a velocidade média dos agentes e médias de distâncias percorridas por cada personalidade.

Desta forma, de acordo com a Fig. (65), as velocidades médias calculadas com a realização de cinquenta simulações, contendo dois agentes de cada personalidade em cada simulação, ou seja, com agentes de cada grupo no total, são:




FIGURA 65: Velocidades Médias e Desvio padrão, para cada personalidade.

Observa-se que, em uma linha crescente, da velocidade média menor para a maior, que tem-se os agentes Experimentais, os agentes Custódias, os agentes Emotivos e os agentes Racionais. Os agentes Custódias, comparados ao ambiente de testes onde havia mais agentes Experimentais e mais agentes Custódias, manteve a segunda menor velocidade média. Os agentes Experimentais mantiveram a mesma posição (primeira) se compararmos os ambientes com mais agentes Custódias e com mais agentes Emotivos. É preciso lembrar que a velocidade pode sofrer alterações de acordo com os custos da caminhada. Esses mesmos custos representam o nível de estresse dos agentes.




FIGURA 66: Distâncias Médias percorridas e Desvio padrão, para cada personalidade.

Verifica-se, em uma linha decrescente, Fig. (66), da maior distância média percorrida para a menor, que tem-se os agentes Experimentais, os agentes Racionais, os agentes Emotivos e os agentes Custódias. Todos os ambientes desbalanceados apresentaram médias de distância percorrida para os agentes Experimentais bem maiores do que para todas as outras personalidade. Possivelmente esse fato ocorra justamente pela relação entre custos e velocidade, que faz com que o agente Experimental possa andar mais tempo pelo ambiente de testes sem grandes penalidades e com velocidades relativamente baixas.

5.4 PROBABILIDADES GERAIS

Os gráficos a seguir foram gerados levando em consideração as médias de todas as seções anteriores.




FIGURA 67: Média de tempo de evacuação de todas as seções anteriores.

Reunindo todas as médias dos resultados anteriores, para as cinquenta simulações tendo, desta forma, seiscentos agentes de cada personalidade ($N=600$), foi possível realizar uma análise em cima do tempo de evacuação de cada uma das personalidades. Observa-se na Fig. (67), que como já foi comentado e justificado, a ordem em tempo de evacuação manteve-se, sendo que os agentes Custódias, mesmo em um ambiente onde eles estão em maior número, são os que saem do ambiente mais rapidamente, possivelmente por sua capacidade de planejamento. Em contrapartida, os agentes Experimentais são os últimos a evacuar, também possivelmente por testarem o ambiente um número maior de vezes do que as outras personalidades. Na segunda posição, alternando poucas vezes para a terceira posição, está o agente Emotivo, que como já foi dito, tem a tendência de seguir outros agentes, fazendo com que este também consiga bons tempos de evacuação. O agente Racional, que não é o melhor planejador, mas também não é um testador, tem tempos médios de evacuação na terceira posição.

Com relação as portas de saída mais utilizadas por cada personalidade tem-se, de acordo com a Fig. (68):




FIGURA 68: Portas de Saída mais utilizadas por cada personalidade levando em consideração todas as seções anteriores.

- a segunda porta de saída do ambiente, também já verificada nas outras análises, é a mais utilizada por todos os agentes, possivelmente pelos baixos custos do corredor e poucos obstáculos;
- assim como a porta 1 de saída do ambiente é a menos utilizada, provavelmente por existir um obstáculo logo que os agentes entram por ela.

Com relação as portas intermediárias do ambiente, Fig. (69) , o que se observa é que para os agentes Custódias, a porta mais utilizada é a porta D, que o leva rapidamente para a saída 2. O mesmo ocorre com os agentes Emotivos.

Já para os agentes Racionais, a porta intermediária mais utilizada é a porta H, possivelmente pelo baixo custo desse agente para chegar até ela. A porta H o direciona para a porta I, que o leva até a porta de saída 2 ou, para a porta J, que o leva para a porta de saída 3.

Os agentes Experimentais também utilizam um número maior de vezes a porta H, contudo sua distribuição entre as outras portas é mais equilibrada do que a distribuição dos outros agentes, justamente pelo fato desse agente ser um agente testador do ambiente.




FIGURA 69: Quantidade do uso de portas por personalidade.

Foi possível calcular as médias gerais para as distâncias percorridas e também para as velocidades, para as quatro personalidades. Assim, de acordo com as Fig. (70) e (71) tem-se:




FIGURA 70: Valor médio das distâncias percorridas por cada personalidade em todas as simulações realizadas.




FIGURA 71: Valor médio das velocidades de cada personalidade em todas as simulações realizadas.

Observa-se que o padrão presente nas seções anteriores foi mantido e representa adequadamente as hipóteses adotadas na metodologia. Assim, se obteve que os agentes Custódias, com melhores tempos de evacuação, também são os agentes que percorrem as menores distâncias e só perdem na velocidade média para os agentes Emotivos (um pouco mais rápidos), provavelmente em função dos custos.

A posição dos agentes Racionais e Experimentais em relação a distância percorrida e velocidade média também demonstram essa relação direta dos resultados com os custos.

5.5 VALIDAÇÃO DOS RESULTADOS

Para que a afirmação feita na Sec. (5.4) dizendo que, *os resultados obtidos em relação aos tempos de evacuação, velocidades médias e distâncias percorridas têm relação direta com os custos*, seja validada, foram realizadas mais cinquenta simulações, com o mesmo ambiente de testes, porém com agentes sem custos.

Assim, as cinquenta simulações foram realizadas no ambiente de testes da Fig. (25), sendo retirados todos os custos dos agentes das quatro personalidades, para que fosse possível comparar os resultados aos resultados já obtidos tanto na Sec. (5.1) como na Sec. (5.4).

O que se obteve foi a escolha de todos os agentes, independentes das personalidades pela porta C e, na sequência, saindo pela porta 1, conforme Fig. (72), ou seja, o resultado do POMDP foi ótimo e todos seguiram pelo caminho mais curto.



FIGURA 72: Simulação com agentes sem custos.

Desta forma, valida-se a afirmação e pode-se dizer que os custos influenciam nas decisões e nos resultados, fazendo com que as hipóteses feitas para as quatro personalidades funcionem como um "humanizador" da simulação, pois o plano de evacuação do agente nem sempre é o plano ótimo. Além disso, as tendências e comportamentos representados na simulação e seus resultados estão de acordo com os apresentados pelos demais autores referenciados.

6 DISCUSSÃO

A escolha de se trabalhar com modelos de Markov deve-se ao fato desses modelos serem grandemente empregados para se analisar ambientes complexos, que é, justamente o tipo de ambiente no qual pedestres circulam. Na verdade, o que torna o ambiente complexo é justamente a existência de comportamentos e personalidades variadas, o que faz com que os processos de decisão sejam difíceis de modelar.

A proposta de se trabalhar com variáveis psicocomportamentais que alimentem um simulador numérico é interessante, visto que a movimentação de pedestres só pode ser bem representada se estas características comportamentais de pessoas reais estiverem presentes no modelo, caso contrário os resultados podem se mostrar contraintuitivos e desconexos com o que realmente ocorre, não só em casos de evacuação, mas também em caminhadas normais.

A hipótese de uso das variáveis psicocomportamentais definidas pela pesquisadora Angela Behrendt se encaixa na proposta do trabalho e foi possível acoplá-las a outras características apresentadas por vários autores da área de dinâmica de multidões, fazendo com que a classificação das variáveis psicocomportamentais usadas para a simulação fossem inéditas e representativas se comparadas à classificação feita por outros autores.

O que pode ser observado nos resultados foram algumas tendências de cada personalidade ou grupo de agentes de mesma identidade. Além disso, foi possível verificar a formação de grupos entre personalidades diferentes, na tentativa de troca de informações para alcançar objetivos. Entre os grupos dos Racionais e dos Custódias, essa característica ficou bem evidente, pois a maior parte deles acabaram optando pela mesma porta de saída. Contudo, nas duas outras personalidades, a porta de saída mais utilizada também teve um percentual elevado, o que representa um comportamento de rebanho descrito por Quarantelli (1957).

Também pode ser verificado que cada grupo representou características particulares, como a de seguir outros agentes, ou testar várias opções de caminhos. Essas características estavam descritas em cada personalidade, foram bem representadas nas simulações e podem ser comparadas às características de multidões apresentadas por Le Bon (2012).

Um fator que foi bem retratado foi justamente a caminhada dos agentes pelos corredores. Benthorn (1998) diz que alguns fatores podem aumentar a atratividade de

uma saída e um deles é a das saídas serem iluminadas ou abertas. Os corredores deste trabalho fizeram esse papel e demonstrou-se na simulação que a maioria dos agentes preferiu seguir por eles.

Ainda segundo Benthorn, o movimento de pedestres em situações de fuga não é necessariamente em linha reta, mas aleatório em uma faixa de terreno. Essa característica ficou representada pelo caminho utilizado pelos agentes durante a evacuação, fato esse possível pelo uso da curva de Bézier para a determinação desse caminho.

Foi possível validar a relação entre a hipótese criada para os custos de cada personalidade com as velocidades médias, o tempo de evacuação e as distâncias percorridas por cada grupo de agentes. Para tal validação comparou-se, usando o mesmo ambiente de testes, os resultados do modelo alimentado com as quatro personalidades tendo os custos de movimentação pré-estabelecidos e resultados com personalidades tendo todos os custos zerados. O resultado claramente indica que os custos distorcem o resultado ótimo e agrega uma parcela "humana" à simulação, pois permite que os agentes cometam erros, bem ilustrado pelos resultados quantitativos.

Foi através da curva de Bézier que as velocidades médias também ficaram bem representadas, pois devido as características de suavização da própria Bézier em que uma curva de raio menor possui mais pontos que uma curva de raio maior, verificava-se que os agentes aumentavam suas velocidades ao avistarem portas ou estando em corredores (raios maiores) e diminuía suas velocidades ao passarem por essas portas ou fazerem curvas fechadas (raios menores). Essa característica da curva aproximou a movimentação dos agentes a uma movimentação de uma pessoa, em relação a variabilidade de velocidade ao andar.

Outras características, fora do foco do trabalho, ainda podem ser retiradas e comparadas a estudos sobre comportamento de pedestres em situações de estresse, mas o que se pode afirmar em função dos resultados obtidos é que, o método de modelagem desenvolvido pode ser utilizado como ferramenta na análise de ambientes que estão sendo preparados para receber pessoas ou que necessitem de saídas de emergência para evacuação rápida de pedestres.

Para que esta análise seja satisfatória, primeiramente é necessário fazer uma pesquisa comportamental na região onde o simulador será aplicado e identificar as personalidades existentes. Em seguida, deve-se quantificar em porcentagens cada uma dessas personalidades identificadas. Por fim essas informações são transcritas no formato de custos, desejos, crenças e intenções de forma que seja possível alimentar o simulador.

Em relação a implementação, a decisão por se programar em Python já foi, durante este texto, muitas vezes justificada, mas é realmente por causa de sua simplicidade

de programação e quantidade de bibliotecas e ferramentas prontas e fáceis de serem utilizadas que se fez essa escolha. Uma dessas ferramentas foi o módulo pyMC, que pode ser alimentado pelos *I-plans*, que são a base deste trabalho, evitando esforço adicional na programação do filtro de partículas.

Infelizmente, não foi possível obter resultados em tempo real ou com muitos agentes, devido à necessidade de um alto poder de processamento e maior capacidade de armazenamento. O tempo para gerar as cinquenta simulações analisadas em cada uma das configurações apresentadas nos resultados foi de, aproximadamente, vinte e cinco horas. O que faz com que esse tempo seja alto é justamente a existência de interações entre os agentes, o que, de certa forma, dificulta a construção do código utilizando programação em paralelo para cada agente.

Quando geraram-se as últimas cinquenta simulações sem custos para os agentes, o tempo para a obtenção de resultados foi de pouco mais de duas horas, valor aquém das simulações anteriores, pois nesse caso o resultado é ótimo e todos se dirigem para o mesmo ponto sem muitas interações entre agentes e com o ambiente. O custo computacional é complicado de ser ilustrado, pois depende da atitude dos agentes em cada simulação, ou seja, quando se tem muitas interações, seja pelo planejamento de cada agente, ou pelas decisões que tomam, o custo computacional tende a se elevar. Um agente sozinho no ambiente, roda de forma relativamente rápida, pouco menos de uma hora, com dois ou mais essa variabilidade do custo já se apresenta, podendo ser uma simulação rápida, algumas horas, ou lenta, várias horas, dependendo do nível de interação entre esses agentes.

7 CONCLUSÕES

A aplicabilidade das teorias envolvidas no problema proposto neste trabalho, seja na área psicocomportamental, como em toda a teoria de Inteligência Artificial contendo agentes com Crenças, Desejos e Intenções (BDI), Processos de Decisão de Markov Parcialmente Observáveis (POMDP), Filtro de Partículas (PF) e *I-plans*, base da metodologia empregada, com a utilização da programação em Python, suas bibliotecas e módulos, que facilitaram a obtenção de resultados, tornou possível alcançar o objetivo principal, que era desenvolver uma modelagem computacional com visualização tridimensional (3D), utilizando inteligência artificial através da geração de *i-plans* bidimensionais, que seja capaz de simular, em função de hipóteses simplificadoras, a movimentação de pessoas em situações de estresse, em ambientes fechados quaisquer, de forma a contribuir com as pesquisas recentes na área de movimentação pedonal, inovando com a implementação de variáveis psicocomportamentais para definir o planejamento de cada agente durante a evacuação do ambiente.

Vale ressaltar que esta pesquisa é iminentemente interdisciplinar, pois propõe uma conjunção da área de ciências sociais, as áreas de matemática e sistemas inteligentes. Todas fornecem subsídios para que o objetivo seja cumprido.

O método de modelagem criado, assumindo variáveis psicocomportamentais e agentes BDI, pode ser aplicado nos mais diversos ambientes. Pode-se citar, por exemplo, o ramo do entretenimento, como casas de shows, estádios de futebol e salas de cinema, que necessitam de tais simuladores para analisar suas estruturas e projeto de evacuação e posicionamento de portas de saída, justamente por serem ambientes que receberão muitas pessoas, com diversas personalidades e que, se não estiverem bem preparados, podem gerar desastres.

Os resultados deste trabalho são um começo promissor, visto que a metodologia de resolução do problema de movimentação apresentada na tese, simula de forma interessante e aproximada o problema da movimentação e fluxo de pedestres em situações de estresse elevado.

8 SUGESTÃO PARA TRABALHOS FUTUROS

Uma extensão desta linha de pesquisa para trabalhos futuros pode ser dada por:

- Refinar a ideia dos custos para cada uma das quatro personalidades através de uma pesquisa psicocomportamental realizada especificamente para um determinado grupo, onde possa se fazer comparações;
- Construir ambientes de caminhada que representem estádios de futebol, casas noturnas, cinemas, etc, onde costumam acontecer acidentes em situações de estresse;
- Comparar os resultados com outros simuladores existentes no mercado.
- Representar os agentes com movimentos semelhantes ao do ser humano, como o de poder dar passos, abrir os braços ou virar a cabeça.
- Testar outras curvas de interpolação para a caminhada dos pedestres, como splines ou nurbs.
- Simular um número maior de agentes para que outras características psicocomportamentais possam ser verificadas.

REFERÊNCIAS

- ACADEMIES, T. N. **Highway Capacity Manual**. 3. ed. [S.l.], 2000.
- AIUBE, F. A. L. **Modelagem dos Preços Futuros de Commodities: Abordagem pelo Filtro de Partículas**. Tese (Doutorado) — Puc-Rio, 2005.
- ALVARES, L. O.; SICHMAN, J. Introdução aos sistemas multiagentes. In: **Jornada de atualização em informática**. [S.l.]: SBC, 1997. p. 1–38.
- ALVES, L. M. **Análise Numérica**. 2013. 1 Dez. <<http://www.lucasmaximoalves.files.wordpress.com/2009/09/analise-numerica.doc>>.
- ASHIDA, K. *et al.* Pedestrians: creating agent behaviors through statistical analysis of observation data. **The Fourteenth Conference on Computer Animation. Proceedings**, p. 84–92, 2001.
- BATISTA, C. S. **Solução de Equações de Balanço Populacional Usando a Técnica de Transformada de Laplace e Filtro de Partículas**. Tese (Doutorado) — Proderna/UFGA, 2011.
- BAUM, L. E.; PETRIE, T. Statistical inference for probabilistic functions of finite state markov chains. **Ann Math. Stat.**, v. 37, p. 1554–1563, 1966.
- BEHRENDT, A. Cooperation and thinking preferences. the importance of understanding our brain. In: UNIVERSIDADE DO ALGARVE - FARO. **ECCI-XII**. [S.l.], 2011.
- BENTHORN, L.; FRANTZICH, H. K. Fire alarm in a public building : How do people evaluate information and choose evacuation exit? In: SHIELDS, J. (Ed.). [S.l.]: Fire-SERT, Univ of Ulster, N Ireland, 1998. p. 213–222.
- BICHO, A. L. **Da modelagem de plantas à dinâmica de multidões: um modelo de animação comportamental bio-inspirado**. Tese (Doutorado) — Universidade Estadual de Campinas, 2009.
- BITTENCOURT, G. **Inteligência Artificial: Ferramentas e Teorias**. Ufsc. [S.l.]: Universidade Federal de Santa Catarina, 2006.
- BOARD, T. R. **Highway Capacity Manual**. Washington, D.C., 1985.
- BON, G. L. **The Crowd: A Study of the Popular Mind**. 2012. 05, Mar. <<http://etext.virginia.edu/toc/modeng/public/BonCrow.html>>.
- BOURNE, E. J. **The Anxiety and Phobia Workbook**. 4. ed. [S.l.]: New Harbinger Press, 2005.
- BRATMAN, M. Two faces of intention. **Philosophical Review**, v. 93, n. 3, p. 375–405, 1984.

BRATMAN, M. **Intention, Plans, and Practical Reason**. [S.l.]: Center for the Study of Language and Information, 1987.

BRATMAN, M. Intention, belief, and instrumental rationality. In: **Reasons for Action**. [S.l.]: Cambridge, 2009.

BRATMAN, M. Intention, belief, practical, theoretical. In: **Spheres of Reason: New Essays in the Philosophy of Normativity**. [S.l.]: Oxford University Press, 2010.

BRILON, W.; GOSSMANN, M.; BLANKE, H. **Verfahren für die Berechnung der Leistungsfähigkeit und Qualität des Verkehrsablaufes auf Strassen**. Alemanha: Bundesministerium für Verkehr, 1994.

BROWN, R. **Social Psychology**. [S.l.]: The Free Press, New York, 1965.

BUCHANAN, B. G.; FEIGENBAUM, E. A. **Dendral and meta-dendral: their applications dimension**. [S.l.]: Artificial Intelligence, 1978. 5-24 p.

BURSTEDDE, C. *et al.* Cellular automaton approach to pedestrian dynamics - applications. **Pedestrian and Evacuation Dynamics**, Springer, p. 87–98, 2002.

BUSSAB, W. O.; MORETTIN, P. A. **Estatística Básica**. [S.l.: s.n.], 2004.

BÉZIER, P. How Renault uses numerical control for car body design and tooling, booktitle = Society of Automotive Engineers Congress, journal = SAE 68001, location = Detroit, Mich., year = 1968. In: . [S.l.: s.n.].

CASSANDRA, A. R.; LITTMAN, M.; ZHANG, N. Incremental pruning: a simple, fast, exact method for partially observable markov decision processes. **13th Annual Conference on Uncertainty in Artificial Intelligence (UAI)**, 1997.

CASTILHO, E.; GUTIERREZ, J. **Expert Systems and Probabilistic Network Models**. [S.l.]: Springer, 1997.

CUPERTINO, A. F. **Filtro de Partículas: O Algoritmo Resample-Move**. Tese (Doutorado) — UFMG, 2007.

DAAMEN, W.; BOVY, P. H. L.; HOOGENDOORN, S. P. Modelling pedestrians in transfer stations. **Pedestrian and Evacuation Dynamics**, Springer, Berlin, p. 59–73, 2002.

DAAMEN, W.; HOOGENDOORN, S. P.; BOVY, P. H. L. First-order pedestrian traffic flow theory. **Transportation Research Record**, v. 1934, n. 1, p. 43–52, 2005.

DAPPER, F. **Planejamento de Movimento para Pedestres utilizando Campos Potenciais**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, 2007.

DESCONHECIDO, A. **Tutorial básico de Python**. 2012. 18 Feb. 2012 <<http://www.codigofonte.net/>>.

DIAS, A. **Curvas e Superfícies de Bézier**. Tese (Doutorado) — Universidade Federal de Santa Catarina - UFSC, Florianópolis, 2000.

DIB, M. V. P.; CARDOSO, D. A.; WEIGANG, L. Sistema para sincronização e gerenciamento de fluxo de tráfego aéreo multi-agentes. **Revista Transportes**, v. 13, n. 1, 2005.

DOUCET, A.; FREITAS, N.; GORDON, N. **Sequential Monte Carlo Methods in Practice**. 1a. ed. [S.l.]: Springer, 2001.

ELLIOTT, D.; SMITH, D. Football stadia disasters in the united kingdom: learning from tragedy? **Industrial and Environmental Crisis Quarterly**, v. 7, p. 205–229, 1993.

EMERSON, E. A.; HALPERN, J. Y. “sometimes” and “not never” revisited: on branching versus linear time temporal logic. **Journal of the ACM**, v. 33, 1986.

FAHY, R. F.; PROULX, G. Evacuation of the world trade center: what went right? **NFPA Journal**, p. 60–67, 1995.

FERNANDEZ, P. J. **Introdução à Teoria das Probabilidades**. 5a. ed. [S.l.]: IMPA, 2011. (Publicações Matemáticas).

FERREIRA, J. M. P. **Departamento de Informática - UEM**. 2012. 2 Mar. <<http://www.din.uem.br/jmpinhei/SI/>>.

FIORI, J. P.; THIELE, R.; RAMOS, A. Z. **Redes Bayesianas e inferência aproximada**. 2012. USP. 14 Feb. <<http://www.lti.pcs.usp.br/pcs2059/aulas/Seminario-G7-doc.pdf>>.

FONNESBECK, C. J. **PYMC 2.3 documentation**. 2014. 11, Fev. <<http://pymc-devs.github.io/pymc/README.html>>.

FORREST, A. R. Interactive interpolation and approximation by bézier polynomials. **Computer-Aided Design**, v. 22, n. 9, p. 527 – 537, 1990.

FOUNDATION, P. S. **Python Documentation**. 2014. 13 Feb. <<http://docs.python.org/2/tutorial/datastructures.html#dictionaries>>.

FOX, D. *et al.* Particle filters for mobile robot localization. In: DOUCET, A.; FREITAS de N.; GORDON, N. (Ed.). **Sequential Monte Carlo Methods in Practice**. New York: Springer Verlag, 2000.

FREITAS, I. M. D. P. **Componentes dos Sistemas de Tráfego**. 2014. 02, Jan. <http://www.transportes.ufba.br/Arquivos/Prof_Ilce/Estudos_de_Trafego_Componente_dos_Siste>.

FRUIN, J. J. Designing for pedestrians. a level-of-service concept. **Highway Research Record**, v. 377, p. 1–15, 1971.

GANEM, J. A behavioral demonstration of fermat’s principle. **The Physics Teacher**, v. 36, n. 2, p. 76–78, 1998.

GORDON, W. J.; RIESENFELD, R. F. Bernstein-bézier methods for the computer-aided design of free-form curves and surfaces. **Journal ACM**, v. 21, n. 2, p. 293–310, 1974.

GUIMARÃES, F. S. **Um Sistema Multi-Agentes para Monitoramento e Aquisição em Tempo Real**. Dissertação (Mestrado) — UFRGS - Instituto de Informática, 2006.

HAMAGAMI, T.; HIRATA, H. Method of crowd simulation by using multiagent on cellular automata. **Intelligent Agent Technology, IEEE / WIC / ACM International Conference on**, IEEE Computer Society, Los Alamitos, CA, USA, v. 0, p. 46, 2003.

- HANSEN, E.; ZHOU, R. Synthesis of hierarchical finite-state controllers for pomdps. **International Conference on Automated Planning and Scheduling (ICAPS. Trento-Italy, 2003.**
- HELBING, D.; FARKAS, I.; VICSEK, T. Simulating dynamical features of escape panic. **Nature**, v. 407, p. 487, 2000.
- HELBING, D.; KELTSCH, J.; MOLNÁR, P. Modeling the evolution of human trail systems. **Nature**, v. 388, p. 47, 1997.
- HELBING, D.; MOLNÁR, P. Social force model for pedestrian dynamics. **Physical Review E**, American Physical Society, v. 51, n. 5, p. 4282–4286, maio 1995.
- HENDERSON, L. F. The statistics of crowd fluids. **Nature**, v. 229, p. 381–383, 1971.
- HO, Y. C.; LEE, R. C. K. A bayesian approach to problems in stochastic estimation and control. **IEEE Trans. Automat. Contr.**, v. 9, p. 333–339, 1964.
- HOOGENDOORN, S.; BOVY, P. H. L. Gas-kinetic modelling and simulation of pedestrian flows. **Transportation Research Record**, National Research Council, v. 1710, n. 189, p. 28–36, 1999.
- HOOGENDOORN, S. P. Microscopic simulation of pedestrian flows. **Civil Engineering**, p. 1–11, 2003.
- HUGHES, R. L. A continuum theory for the flow of pedestrians. **Transportation Research Part B: Methodological**, Elsevier, v. 36, n. 6, p. 507–535, 2002.
- JAMES, B. R. **Probabilidade: Um Curso em Nível Intermediário**. [S.l.]: IMPA, 1996.
- JUSTINIANO, P. **Introdução a Inferência Bayesiana**. 2012. 03, Mar. <<http://www.leg.ufpr.br/paulojus/CE227/ce227/node5.html>>.
- KAEHLING, L. P.; LITTMAN, M.; CASSANDRA, A. R. Planning and acting in partially observable stochastic domains. **Artificial Intelligence**, v. 101, 1998.
- KEATING, J. P. The myth of panic. **Fire Journal**, 1982.
- KERNER, B. S. **The physics of traffic**. [S.l.]: Springer Verlag, 2004.
- KLERMAN, G. L.; HIRSCHFELD, R. M. A.; WEISSMAN, M. M. **Panic Anxiety and Its Treatments: Report of the World Psychiatric Association Presidential Educational Program Task Force**. [S.l.: s.n.], 1993.
- KORB, K. B.; NICHOLSON, A. E. **Bayesian artificial intelligence**. [S.l.]: Chapman e Hall/CRC Press UK, 2004.
- LARRAÑAGA, A. M. **Análise do Padrão Comportamental de Pedestres**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, 2008.
- LEBACQUE, J. P.; KHOSHYARAN, M. M. First order traffic flow models: intersection modeling, network modeling, applications. **Proc of Mathematical Models of Traffic Flow**, 2005.

LERNER, A. *et al.* Fitting behaviors to pedestrian simulations. In: **Proceedings of the 2009 ACM SIGGRAPH/Eurographics Symposium on Computer Animation**. New York, NY, USA: ACM, 2009. (SCA '09), p. 199–208.

LIN, L.-J.; MITCHELL, T. M. **Memory Approaches To Reinforcement Learning In Non-Markovian Domains**. [S.l.], 1992.

LOVEJOY, W. S. Computationally feasible bounds for partially observed markov decision processes. **Oper. Res.**, INFORMS, v. 39, p. 162–175, 1991.

MAGALHÃES, M. N. **Probabilidade e Variáveis Aleatórias**. 3a. ed. [S.l.]: Edusp, 2011.

MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. H. **Introduction to Information Retrieval**. New York, NY, USA: Cambridge University Press, 2008.

MCCARTHY, J. **Lisp 1.5 Programmer's Manual**. [S.l.]: Cambridge, Massachusetts: The MIT Press, 1962.

MINTZ, A. Non-adaptive group behavior. **Journal of Abnormal Psychology**, v. 46, n. 2, p. 150–159, 1951.

MORITA, M.; OLIVEIRA, L.S. **Introdução aos Modelos Escondidos de Markov**. Technical Report (PPGIA), PUCPR: Curitiba-Paraná, 1998

NAIR, R.; TAMBE, M. Hybrid bdi-pomdp framework for multiagent teaming. **J. Artif. Int. Res.**, AI Access Foundation, v. 23, p. 367–420, April 2005.

NOGUEIRA, F. **Notas de Aula**. 2012. 29 Feb. <<http://www.ufjf.br/epd042/files/2009/02/cadeiaMarkov.pdf>>.

NORVIG, P.; RUSSELL, S. J. **Inteligência Artificial**. [S.l.]: Campus, 2004.

OLDER, S. J. Movement of pedestrians on footways in shopping streets. **Traffic Engineering and Control**, v. 10, n. 4, p. 160–163, 1968.

PARUCHURI, P. *et al.* **Multiagent Teamwork: Hybrid Approaches**. 2006.

PEARL, J. **Probabilistic Reasoning in Intelligent Systems**. [S.l.]: Morgan Kaufmann, 1988.

PELLEGRINI, J. **Processos de Decisão de Markov Limitados por Linguagem**. Tese (Doutorado) — UNICAMP, 2006.

PELLEGRINI, J.; WAINER, J. Processos de decisão de markov: Um tutorial. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, 2007.

PEREIRA, D. R. **Construção de Planos BDI a partir de Políticas Ótimas de POMDPs, com Aplicação na Auto-Regulação de Trocas Sociais em Sistemas Multiagentes**. Dissertação (Mestrado) — Universidade Católica de Pelotas, Abr 2008.

PEREIRA, G.; SAITO, M.; PEDRUZZI, P. **Planejamento no mundo real**. 2012. 12, Mar. <www.lti.pcs.usp.br/pcs2059/aulas/Seminario-G4-doc.pdf>. Escola Politécnica da Universidade de São Paulo - Departamento de Engenharia de Computação e Sistemas Digitais.

PETTELE. **Tutorial de Introdução ao Python**. Niterói-RJ, 2011.

PORTZ, A.; SEYFRIED, A. Modeling stop-and-go waves in pedestrian dynamics. In: **Proceedings of the 8th international conference on Parallel processing and applied mathematics: Part II**. Berlin, Heidelberg: Springer-Verlag, 2010. p. 561–568.

POUPART, P.; BOUTILIER, C. Bounded finite state controllers. **Conference on Neural Information Processing Systems (NIPS)**., 2003.

PREDTETSCHENSKI, W. M.; MILINSKI, A. I. **Personenströme in Gebäuden - Berechnungsmethoden für die Projektierung**. [S.l.]: Köln-Braunsfeld, 1971.

PYSCIENTE. **SciPy**. 2012. 18 Feb. 2012 <<http://pyscience-brasil.wikidot.com/module:scipy>>.

QUARANTELLI, E. The behavior of panic participants. **Sociology and social research**, v. 41, p. 187–194, 1957.

RABINER, L. R. A tutorial on hidden markov models and selected applications in speech recognition. **Proceedings of the IEEE**, v. 77, n. 2, 1989.

REIS, L. P. **Coordenação em Sistemas Multi-Agente: Aplicações na Gestão Universitária e Futebol Robótico**. Tese (Doutorado) — Universidade do Porto - Faculdade de Engenharia - FEUP, Jul 2003.

REKLEITIS, I. M. **A Particle Filter Tutorial for Mobile Robot Localization TR-CIM-04-02**. Dissertação (Mestrado) — Centre for Intelligent Machines, McGill University, 2004.

RENS, G.; FERREIN, A.; POEL, E. v d. A bdi agent architecture for a pomdp planner. In: **Nineth International Symposium on Logical Formalizations of Commonsense Reasoning**. Toronto, Canada: [s.n.], 2009.

RHEINGOLD, H. **EXPERT SYSTEMS**. 2012. 28 Feb. <<http://www.atariarchives.org/deli/>>.

ROY, N. **Finding Approximate POMDP solutions Through Belief Compression**. Tese (Doutorado) — Robotics Institute, Carnegie Mellon University, Sep 2003.

SARKAR, A. K.; JANARDHAN, K. S. V. S. A study on pedestrian flow characteristics. In: **Proceedings of the Annual Meeting of the Transportation Research Board**. [S.l.]: Transportation Research Board, National Research Council, 1997.

SCHADSCHNEIDER, A. Cellular automaton approach to pedestrian dynamics - theory. **Pedestrian and Evacuation Dynamics**, Springer, p. 75–86, 2002.

SCHADSCHNEIDER, A.; SEYFRIED, A. Validation of ca models of pedestrian dynamics with fundamental diagrams. **Cybernetics and Systems**, Taylor and Francis Ltd, v. 40, n. 5, p. 367–389, 2009.

SCHERER, D. 3d programming for ordinary mortals. **VPython.org**, 2014.

SHORTLIFFE, E. H. **Computer-based medical consultations: MYCIN**. [S.l.]: New York: American Elsevier, 1976.

SIMARI, G. I.; PARSONS, S. On the relationship between mdps and the bdi architecture. In: **Proceedings of the fifth international joint conference on Autonomous agents and multiagent systems**. [S.l.]: ACM, 2006. (AAMAS '06), p. 1041–1048.

SOUZA, E. E.; NETTO, M. L. **Sistemas Multi-Agentes Aplicados à TV a Cabo**. 2012. 28 Feb. <<http://www.lsi.usp.br/lobonett/publications/>>.

STEINBERG, J. G. **Desenvolvimento de modelo para simulação de situações de evacuação de multidões**. Tese (Doutorado) — Universidade Estadual de Campinas, 2005.

STEMMER, M. R. *et al.* **Apostila de Sistemas de Visão**. [S.l.]: Sistemas Industriais Inteligentes, 2005.

TANABORIBOON, Y.; HWA, S. S.; CHOR, C. H. Pedestrian characteristics study in singapore. **Journal of Transportation Engineering - ASCE**, v. 112, n. 3, 1986.

TEKNOMO, K. Application of microscopic pedestrian simulation model, journal = Transportation Research Part F, volume = 9, pages = 15-27, year = 2006.

THRUN, S.; NORVIG, P. **Introduction to Artificial Intelligence - Stanford Engineering**. 2011. 01 Nov. <<https://www.ai-class.com/home/>>.

TOYAMA, M. C. **Uma abordagem multiagente para dinâmica de pedestres**. Dissertação (Mestrado) — PUC-RIO - Departamento de Informática, 2006.

TURNER, R. H.; KILLIAN, L. M. **Collective behavior**. [S.l.]: Prentice-Hall, 1972.

UFPE. **Métodos Matemáticos 1A - Cadeias de Markov**. 2012. 29 Feb. <<http://www2.ee.ufpe.br/codec/Markov.pdf>>.

ULLRICH, H. **Mechanische Verfahrenstechnik: Berechnung Und Projektierung**. [S.l.]: Springer-Verlag GmbH, 1967.

VALENTIN, M. V.; ONO, R. Saídas de emergência e comportamento humano: Uma abordagem histórica e o estado atual da arte no brasil. In: **NUTAU**. [S.l.: s.n.], 2006.

VENUTI, F.; BRUNO, L. An interpretative model of the pedestrian fundamental relation. **Comptes Rendus Mécanique**, v. 335, n. 4, p. 194–200, 2007.

VIRKLER, M. R.; ELAYADATH, S. Pedestrian speed-flow-density relationships. **Transportation Research Record**, n. 1438, p. 51–58, 1994.

WEIDMANN, U. **Transporttechnik der Fußgänger**. [S.l.]: ETH Zürich, 1993.

WEIDMANN, U.; BUCHMUELLER, S. Parameters of pedestrians, pedestrian traffic and walking facilities,. **ETH Zürich**, 2006.

WOOLDRIDGE, M. **An Introduction to MultiAgent Systems**. [S.l.]: Baffins Lane: John Wiley e Sons, 2002.

ZAMPIERI, F. L. L. **Modelo Estimativo de Movimento de Pedestres baseado em sintaxe espacial, medidas de desempenho e redes neurais artificiais**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, 2006.